

INSTITUTO FEDERAL DE SANTA CATARINA

KAROLINE DA ROCHA

**Detecção Automática de Vértexes em Imagens  
Médicas Usando SVM**

São José - SC

Agosto/2017

Karoline da Rocha

# **Detecção Automática de Vértexes em Imagens Médicas Usando SVM**

Trabalho de Conclusão de Curso apresentada  
ao curso de Engenharia de Telecomunicações  
do campus São José do Instituto Federal de  
Santa Catarina para obtenção do diploma de  
Engenheira de Telecomunicações.

Instituto Federal de Santa Catarina – IFSC

Campus São José

Engenharia de Telecomunicações

Orientador: Prof. Marcos Moecke, Dr

São José - SC

Agosto/2017

Karoline da Rocha

Detecção Automática de Vértexbras em Imagens Médicas Usando SVM/  
Karoline da Rocha. – São José - SC, Agosto/2017-  
83 p. : il. (algumas color.) ; 30 cm.

Orientador: Prof. Marcos Moecke, Dr

Monografia (Graduação) – Instituto Federal de Santa Catarina – IFSC  
Campus São José  
Engenharia de Telecomunicações, Agosto/2017.

1. SVM. 2. Imagem médica. 3. Detecção de vértebra. I. Prof. Marcos Moecke, Dr.  
II. Instituto Federal de Santa Catarina. III. Campus São José. IV. Detecção Automática  
de Vértexbras em Imagens Médicas Usando SVM

Karoline da Rocha

## **Detecção Automática de Vértexes em Imagens Médicas Usando SVM**

Trabalho de Conclusão de Curso apresentada  
ao curso de Engenharia de Telecomunicações  
do campus São José do Instituto Federal de  
Santa Catarina para obtenção do diploma de  
Engenheira de Telecomunicações.

Trabalho aprovado. São José - SC, 11 de agosto de 2017:

---

**Prof. Marcos Moecke, Dr**  
Orientador - IFSC

---

**Prof. Diego da Silva de Medeiros, Me.**  
Avaliador - IFSC

---

**Prof. Ramon Mayor Martins, Me.**  
Avaliador - IFSC

São José - SC  
Agosto/2017

# Agradecimentos

A Deus por ter me concedido saúde e força para superar todas as dificuldades que encontrei ao longo desses 5 anos de graduação.

Aos meus pais e ao meu irmão, por sempre estarem ao meu lado dando todo o apoio, atenção e carinho. Essa vitória também é de vocês!

Ao meu namorado por toda a sua ajuda, carinho e paciência nesses últimos anos. Muito obrigada por tudo!

A minha avó Maria Eli da Rocha, por todos os conselhos, carinho, atenção e por todas orações antes das provas e trabalhos mais difíceis do curso. A quase um ano, ela tornou-se a estrela mais linda e brilhante do céu! Amo você muito!

Aos amigos que encontrei ao longo desse curso, vocês foram a minha segunda família. Principalmente a Ana Luiza Scharf, André Felipe Weber e Guilherme de Albuquerque. Por todas as nossas conversas, risadas, tardes e noites de estudos, essas foram fundamentais para eu ter chego até aqui.

Aos meus amigos de uma vida inteira, por entenderem minha ausência devido as tarefas do curso. Principalmente por estarem ao meu lado nos momentos que mais precisei de apoio e de consolo.

A todos os professores que tive durante o curso, que de uma forma ou de outra marcaram minha vida. Em especial ao meu orientador Marcos Moecke, por toda a sua paciência e auxílio. Seus conhecimentos e incentivos foram essenciais para a realização deste trabalho.

E a empresa onde estagiei, Pixon Medical Systems, agradeço ao pessoal do setor de desenvolvimento, aos meus supervisores de estágio Rafael Hancke e Leandro dos Anjos Moura, e ao meu coordenador de estágio Tiago D'Agostini, por todo o suporte, paciência, compreensão e auxílio que tiveram comigo no decorrer desses 10 meses de estágio. Também agradeço a Pixon por ter fornecido as imagens médicas anonimizadas utilizadas neste trabalho.

*"Se vi mais longe foi por estar  
de pé sobre ombros de gigantes."  
(Isaac Newton)*

# Resumo

A identificação e designação das vértebras são as etapas iniciais no processo de diagnóstico para imagens médicas da coluna vertebral. O desenvolvimento de técnicas de auxílio ou automatização dessas etapas permitirá acelerar o processo de diagnóstico. Esta pesquisa visa realizar a detecção automática das vértebras (cervical, torácica e lombar) em imagens médicas. A técnica aplicada foi uma combinação de descritores HOG (*Histogram of Oriented Gradients*) com o classificador SVM (*Support Vector Machine*) juntamente com métodos de busca pela imagem. No treinamento do classificador SVM, foram utilizadas 140 amostras de imagens, sendo metade delas vértebras. Foram propostos três métodos de busca, sendo o primeiro uma “busca exaustiva” nas direções horizontal e vertical da imagem, sem alterar a inclinação e a escala da janela de detecção. No segundo método, depois de identificar a primeira vértebra como anteriormente, restringe-se a busca da próxima vértebra para uma região logo abaixo ou acima da vértebra anterior, alterando também o ângulo e o fator de escala da região analisada. O terceiro método acelera o Método 2 reduzindo o número de classificações SVM. Os resultados mostram que o Método 3 encontrou todas as vértebras presentes nas imagens médicas avaliadas, com uma redução de 97% do tempo de busca em relação ao Método 2.

**Palavras-chave:** Detecção de vértebras. Descritor HOG. Imagens médicas. Métodos de procura. Classificador SVM.

# Abstract

Vertebrae identification and designation are the initial steps in the diagnosis process for spine medical images. Developing techniques for aiding or automation these steps will accelerate the diagnostic process. This research aims to carry out the automatic detection of the vertebrae (cervical, thoracic and lumbar) in medical images. The technique applied was a combination of HOG (Histogram of Oriented Gradients) descriptors with the SVM (Support Vector Machine) classifier, along with image search methods. In SVM classifier training, 140 samples of images were used, half of which were vertebrae. Three search methods were proposed, the first is an “exhaustive search” in the horizontal and vertical directions of the image, without changing the tilt and scale of the detection window. In the second method, after identifying the first vertebra as before, the search for the next vertebra is restricted to a region just below or above the anterior vertebra, also changing the angle and scaling factor of the analysed region. The third method accelerates Method 2 by reducing the number of SVM classifications. The results show that Method 3 found all the vertebrae present in the medical images evaluated with a reduction of 97% of the search time in relation to Method 2.

**Keywords:** Vertebrae detection. HOG descriptor. Medical images. Search methods. SVM classifier.



# Lista de ilustrações

Figura 1 – Disposição das vértebras na coluna vertebral. . . . .	17
Figura 2 – Região do processo espinhoso destacada. . . . .	18
Figura 3 – Diferenciação das vértebras pelo formato. . . . .	19
Figura 4 – Ilustração das vértebras nas três vistas anatômicas. . . . .	19
Figura 5 – Configuração básica do equipamento de radiografia. . . . .	20
Figura 6 – Configuração básica do equipamento de tomografia computadorizada. . . . .	21
Figura 7 – Equipamento de ressonância magnética. . . . .	23
Figura 8 – Etapas do algoritmo SIFT. . . . .	25
Figura 9 – Reconhecimento de objetos em imagens, utilizando SIFT. . . . .	26
Figura 10 – Etapas do algoritmo HOG. . . . .	27
Figura 11 – Exemplo da etapa de pré-processamento do HOG: (a) Imagem original, com uma região selecionada. (b) Corte da região selecionada (54x54 <i>px</i> ). (c) Região redimensionada para um dos tamanhos da janela de detecção (48x48 <i>px</i> ). . . . .	27
Figura 12 – Criação dos Histogramas das células na terceira etapa do HOG. . . . .	28
Figura 13 – Ilustração da sobreposição dos blocos na janela de detecção, durante a criação do descritor HOG. . . . .	29
Figura 14 – Interpolação bilinear. . . . .	30
Figura 15 – Exemplo de interpolação bilinear: (a) Imagem original (61x60 <i>px</i> ). (b) Imagem rotacionada e redimensionada com interpolador bilinear (50x58 <i>px</i> ). . . . .	31
Figura 16 – Ilustração de classes não linearmente separáveis. . . . .	32
Figura 17 – Ilustração de dois hiperplanos que separam as amostras em duas classes. . . . .	32
Figura 18 – Comparação das dimensões da janela de detecção. . . . .	35
Figura 19 – Ilustração da quantidade de células e <i>pixels</i> para demonstrar a criação do descritor HOG. . . . .	36
Figura 20 – Ilustração dos histogramas utilizados para geração do descritor HOG. . . . .	36
Figura 21 – Estrutura do descritor HOG. . . . .	37
Figura 22 – Etapas realizadas pela ferramenta de recorte: (a) 1º etapa - Seleção da região com dois pontos extremos a esquerda. (b) 2º etapa - Recorte da região selecionada e escolha da dimensão da janela de detecção. (c) Recorte da região na dimensão escolhida (48x48 <i>px</i> ) e classificação se é ou não uma vértebra. . . . .	38
Figura 23 – Fase de classificação SVM. . . . .	39
Figura 24 – Cores dos retângulos com suas respectivas notas do classificador. . . . .	40
Figura 25 – Fluxograma do Método 1. . . . .	41

Figura 26 – Fluxograma dos Métodos 2 e 3. . . . .	43
Figura 27 – Exemplo da área de procura do Método 2, após encontrar a primeira vértebra. . . . .	44
Figura 28 – Análise das notas obtidas com o Método 2, variando os 5 parâmetros de uma região analisada. . . . .	45
Figura 29 – Vértebras detectadas na imagem de teste 1, com o Método 1. . . . .	49
Figura 30 – Vértebras detectadas na imagem de teste 1, com o Método 2. . . . .	51
Figura 31 – Vértebras detectadas na imagem de teste 1, com o Método 3. . . . .	52
Figura 32 – Imagens no formato DICOM utilizadas no treinamento do classificador SVM. . . . .	65
Figura 33 – Imagens no formato DICOM utilizadas no treinamento do classificador SVM (cont.) . . . . .	66
Figura 34 – Imagens no formato DICOM utilizadas no treinamento do classificador SVM (cont.) . . . . .	67
Figura 35 – Amostras das imagens utilizadas no treinamento do classificador SVM.	68
Figura 36 – Amostras das imagens utilizadas no treinamento do classificador SVM (cont.) . . . . .	69
Figura 37 – Amostras das imagens utilizadas no treinamento do classificador SVM (cont.) . . . . .	70
Figura 38 – Imagens médicas utilizadas nos testes de detecção de vértebras. . . . .	71
Figura 39 – Regiões detectadas como vértebras com o Método 1 para a imagem de teste 2. . . . .	75
Figura 40 – Regiões detectadas como vértebras com o Método 1 para a imagem de teste 3. . . . .	76
Figura 41 – Regiões detectadas como vértebras com o Método 1 para a imagem de teste 4. . . . .	77
Figura 42 – Regiões detectadas como vértebras com o Método 2 para a imagem de teste 2. . . . .	78
Figura 43 – Regiões detectadas como vértebras com o Método 2 para a imagem de teste 3. . . . .	79
Figura 44 – Regiões detectadas como vértebras com o Método 2 para a imagem de teste 4. . . . .	80
Figura 45 – Regiões detectadas como vértebras com o Método 3 para a imagem de teste 2. . . . .	81
Figura 46 – Regiões detectadas como vértebras com o Método 3 para a imagem de teste 3. . . . .	82
Figura 47 – Regiões detectadas como vértebras com o Método 3 para a imagem de teste 4. . . . .	83

# Lista de tabelas

Tabela 1 – Escala de <i>Hounsfield</i> . . . . .	22
Tabela 2 – Quantidade de <i>bits</i> por <i>pixel</i> , por modalidade. . . . .	24
Tabela 3 – Especificação do computador utilizado para adquirir os resultados. . .	46
Tabela 4 – Número de regiões treinadas em cada proporção. . . . .	46
Tabela 5 – Especificações das imagens treinadas. . . . .	47
Tabela 6 – Informações das imagens utilizadas nos testes. . . . .	48
Tabela 7 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 1. Imagem de teste 1. . . . .	49
Tabela 8 – Tempos em minutos utilizados nas etapas do Método 1. . . . .	50
Tabela 9 – Detalhes das classificações nas imagens teste utilizando o Método 1. . .	50
Tabela 10 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 2. Imagem de teste 1. . . . .	51
Tabela 11 – Detalhes das classificações nas imagens teste utilizando o método 2. . .	52
Tabela 12 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 3. Imagem de teste 1. . . . .	53
Tabela 13 – Detalhes das classificações nas imagens teste utilizando o método 3. . .	53
Tabela 14 – Comparação dos resultados obtidos nos 3 métodos. . . . .	54
Tabela 15 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 1. Imagem de teste 2. . . . .	75
Tabela 16 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 1. Imagem de teste 3. . . . .	76
Tabela 17 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 1. Imagem de teste 4. . . . .	77
Tabela 18 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 2. Imagem de teste 2. . . . .	78
Tabela 19 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 2. Imagem de teste 3. . . . .	79
Tabela 20 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 2. Imagem de teste 4. . . . .	80
Tabela 21 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 3. Imagem de teste 2. . . . .	81
Tabela 22 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 3. Imagem de teste 3. . . . .	82
Tabela 23 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 3. Imagem de teste 4. . . . .	83

# Lista de abreviaturas e siglas

<b>ACR</b> <i>American College Of Radiology</i> .....	23
<b>CT</b> Tomografia Computadorizada .....	21
<b>DICOM</b> <i>Digital Imaging and Communications in Medicine</i> .....	15
<b>DoG</b> Diferença de Gaussianas .....	25
<b>EUA</b> Estados Unidos da América .....	23
<b>HOG</b> <i>Histogram of Oriented Gradients</i> .....	14
<b>mm</b> milímetros .....	40
<b>MRI</b> Imagem por Ressonância Magnética .....	22
<b>NEMA</b> <i>National Eletrical Manufacturers Association</i> .....	23
<b>RF</b> Radiofrequência .....	22
<b>SIFT</b> <i>Scale-Invariant Feature Transform</i> .....	14
<b>SVM</b> <i>Support Vector Machine</i> .....	14
<b>T</b> Tesla .....	22

# Sumário

	<b>Sumário</b>	<b>12</b>
<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
1.1	Objetivo	15
1.2	Organização do texto	15
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>17</b>
2.1	Introdução	17
2.2	Anatomia da coluna vertebral	17
2.3	Modalidades de aquisição de imagens médicas	20
2.3.1	Radiografia	20
2.3.2	Tomografia Computadorizada (CT)	21
2.3.3	Imagem por Ressonância Magnética (MRI)	22
2.4	Padrão DICOM	23
2.5	Algoritmos descritores de características	24
2.5.1	<i>Scale-Invariant Feature Transform</i> (SIFT)	25
2.5.2	<i>Histogram of Oriented Gradients</i> (HOG)	26
2.6	Interpolador Bilinear	29
2.7	Classificador	31
2.7.1	<i>Support Vector Machine</i> (SVM)	31
<b>3</b>	<b>DESENVOLVIMENTO</b>	<b>34</b>
3.1	Ambiente de desenvolvimento	34
3.2	Base de dados de imagens	34
3.3	Técnicas usadas na detecção das vértebras	34
3.3.1	Implementação do Descritor HOG	35
3.3.2	Treinamento da SVM	37
3.3.3	Classificação das regiões testes	38
3.4	Métodos de procura das vértebras nas imagens	39
3.4.1	Método 1	41
3.4.2	Método 2	42
3.4.3	Método 3	44
<b>4</b>	<b>RESULTADOS</b>	<b>46</b>
4.1	Ambiente de trabalho	46
4.2	Treinamento da SVM	46

<b>4.3</b>	<b>Métodos de procura na imagem . . . . .</b>	<b>47</b>
4.3.1	Método 1 . . . . .	48
4.3.2	Método 2 . . . . .	50
4.3.3	Método 3 . . . . .	52
<b>4.4</b>	<b>Análise dos resultados . . . . .</b>	<b>53</b>
<b>5</b>	<b>CONCLUSÕES . . . . .</b>	<b>55</b>
5.1	Trabalhos futuros . . . . .	56
	<b>REFERÊNCIAS . . . . .</b>	<b>58</b>
	<b>APÊNDICES . . . . .</b>	<b>62</b>
	<b>APÊNDICE A –</b>	
	<b>INFORMAÇÃO DAS TAGS DICOM . . . . .</b>	<b>63</b>
	<b>APÊNDICE B – . . . . .</b>	<b>65</b>
	<b>APÊNDICE C – . . . . .</b>	<b>68</b>
	<b>APÊNDICE D – . . . . .</b>	<b>71</b>
	<b>APÊNDICE E – PSEUDOCÓDIGO DOS 3 MÉTODOS . . . . .</b>	<b>72</b>
	<b>APÊNDICE F – MÉTODO 1: RESULTADOS . . . . .</b>	<b>75</b>
	<b>APÊNDICE G – MÉTODO 2: RESULTADOS . . . . .</b>	<b>78</b>
	<b>APÊNDICE H – MÉTODO 3: RESULTADOS . . . . .</b>	<b>81</b>

# 1 Introdução

Pesquisas realizadas em 2014 e 2015, pelo INSS (Instituto Nacional de Seguridade Social) no Brasil, relatam que a terceira causa de afastamento do trabalho é devido a dores nas costas (MOREIRA; GERCINA, 2014; SOCIAL, 2016). Para averiguar as causas das dores nas costas faz-se necessário exames específicos (e.g.: Tomografia Computadorizadas - CT, Imagem por Ressonância Magnéticas - MRI ou raio X convencional), juntamente com diagnósticos médicos. A identificação e a designação das vértebras nas imagens são dois dos primeiros passos durante os diagnósticos médicos da coluna vertebral, técnicas que possam auxiliar e até mesmo automatizar esses dois passos permitiriam que os médicos dedicassem mais tempo na análise e no diagnóstico das imagens adquiridas da coluna do paciente.

A área de detecção e reconhecimento de vértebras vem sendo alvo de uma série de estudos e pesquisas (SA et al., 2016; LOOTUS; KADIR; ZISSERMAN, 2013a; OKTAY; AKGUL, 2013). Nessas pesquisas comumente são utilizados algoritmos descritores de características, os quais descrevem as vértebras pelo seu formato, e sucessivamente esses descritores alimentam ferramentas de aprendizagem de máquina supervisionada. Após um treinamento com amostras conhecidas, essas ferramentas tornam possível a detecção semiautomática/automática das vértebras.

Dentre os algoritmos descritores de características que estão mais presente no estado da arte de detecção de vértebras são: *Scale-Invariant Feature Transform* (SIFT) e *Histogram of Oriented Gradients* (HOG), e estes normalmente estão atrelados a ferramenta de aprendizagem de máquina supervisionada, conhecida por *Support Vector Machine* (SVM).

Os algoritmos descritores SIFT apresentam uma complexidade maior que o *Histogram of Oriented Gradients* (HOG) em sua implementação, pelo fato de extraírem as características dos objetos por partes (pontos-chaves), mas isso torna possível que ele seja utilizado para auxiliar na detecção de objetos parcialmente obstruídos (SILVA, 2014). Em contrapartida, os algoritmos HOG possuem uma implementação menos complexa em relação ao SIFT, pois extraem as características dos objetos como um todo, obtendo bons resultados para objetos que não estejam obstruídos (COSMO, 2014). Compreendendo a diferença entre os dois algoritmos, e considerando que o objeto analisado nessa pesquisa são vértebras na vista sagital, sem obstrução por outros objetos, pode-se supor que o uso do SIFT não apresentará muitas vantagens em relação ao HOG. Dessa forma, optou-se em utilizar como algoritmo descritor de característica o HOG, aplicando-o para alimentar o classificador *Support Vector Machine* (SVM). A disponibilidade da implementação do

algoritmo HOG e da ferramenta SVM em McCormick (2013) foi outro fator que contribuiu para essa escolha, apesar da necessidade de ter que adaptar o algoritmo HOG de detecção de pessoas para vértebras.

Neste trabalho foram desenvolvidos e avaliados 3 métodos de procura das vértebras em imagens médicas. Todos foram implementados com o auxílio do algoritmo HOG, o qual descreve as características da região baseado nos seus gradientes, seguida de um classificador SVM para classificar a região analisada como vértebra ou não vértebra. Para os 3 métodos a fase de treinamento da SVM foi única e realizada em uma única vez.

## 1.1 Objetivo

Este trabalho, foi desenvolvido em conjunto com o estágio realizado na empresa Pixon Medical Systems, e propõe-se a desenvolver um algoritmo para detectar de forma automática, as vértebras a partir de imagens médicas armazenadas no padrão *Digital Imaging and Communications in Medicine* (DICOM) (FICEL, 2006a). Dentre as vértebras visa-se detectar as vértebras cervicais, torácicas e lombares.

Para atingir o objetivo principal, serão necessários alcançar os seguintes objetivos específicos:

- Implementar ou adaptar um algoritmo descritor de característica HOG e um classificador SVM, para imagens médicas;
- Selecionar amostras de vértebras e não vértebras para realizar o treinamento do classificador SVM;
- Elaborar métodos de procura por vértebras nas imagens médicas de modo a não ter falsos positivos nem negativos e com um baixo custo computacional.

## 1.2 Organização do texto

Este trabalho está organizado da seguinte forma: no Capítulo 2 é apresentada uma sucinta descrição da anatomia da coluna vertebral, são abordadas três modalidades de aquisição de imagens médicas, aspectos relevantes do padrão DICOM, dos algoritmos descritores de características e do classificador utilizado neste trabalho. Optou-se por não apresentar nenhum material sobre processamento de imagem digital, mas recomenda-se a referência Gonzalez (2010). No Capítulo 3 é apresentado o ambiente onde este trabalho foi desenvolvido, as informações do banco de dados utilizado, descrição das técnicas utilizadas e das metodologias adotadas nos 3 métodos de procura. No Capítulo 4 são apresentadas as informações das imagens utilizadas no treinamento, mostrados e analisados os resultados



obtidos nos 3 métodos de procura propostos. Por fim, o Capítulo 5 apresenta as principais conclusões e sugestões para trabalhos futuros. Para facilitar a visualização das imagens, foram utilizadas cores em muitas figuras, por isso recomenda-se que o trabalho seja lido na sua versão em pdf (ADOBE, 2017) ou em impressão colorida.

## 2 Fundamentação Teórica

### 2.1 Introdução


Este capítulo apresenta conceitos, técnicas e algoritmos que são usados no desenvolvimento desta pesquisa. Primeiramente será definido a anatomia básica da coluna vertebral, seguida de algumas modalidades de aquisição de imagens, e uma explicação básica sobre o padrão DICOM. Por fim algumas técnicas e algoritmos utilizados na detecção de objetos.

### 2.2 Anatomia da coluna vertebral

A coluna vertebral inicia na base do crânio e vai até a extremidade caudal do tronco. Ela fornece a sustentação dos seres humanos para terem a posição bípede, além de conter internamente a medula espinhal, responsável pela comunicação entre o sistema nervoso central e o sistema nervoso periférico (COSTA et al., 2013). A coluna é composta por tecidos conjuntivos e por vários ossos, os quais são denominados de vértebras. Elas estão dispostas umas sobre as outras, na forma de uma coluna, por isso o nome coluna vertebral (ANATOMIA, 2001).

A coluna vertebral é formada por 33 vértebras, sendo subdividida em **5 regiões**: **cervical** (com 7 vértebras), **torácica** (com 12 vértebras), **lombar** (com 5 vértebras), **sacro** (com 5 vértebras) e **cóccix** (com 4 vértebras), conforme mostrado na Figura 1 (COSTA et al., 2013).


Figura 1 – Disposição das vértebras na coluna vertebral.



Fonte: (ANATOMIA, 2001).

Entre duas vértebras vizinhas estão os discos intervertebrais, que possibilitam os movimentos da coluna vertebral e são responsáveis pela absorção dos impactos. Cada vértebra possui uma característica física própria, o que facilita a sua identificação. As vértebras recebem uma numeração conforme ilustrado na Figura 2.

Figura 2 – Região do processo espinhoso destacada.




Fonte: (DISCO, 2015).

As vértebras cervicais (C1 à C7) tem a função de sustentação da cabeça, possuem um tecido ósseo mais denso que as demais e são as menores vértebras (COSTA et al., 2013). As vértebras torácicas (T1 à T12) são maiores que as cervicais, e aumentam de tamanho a medida que descem na coluna vertebral. Elas tem como característica a presença de um processo espinhoso mais longo e inclinado para baixo, conforme destacado no círculo vermelho da Figura 2 (COSTA et al., 2013). As vértebras lombares (L1 à L5) são facilmente identificadas por serem as maiores da coluna vertebral, e possuírem os processos espinhosos mais densos, com isso seu corpo vertebral é grande e largo (COSTA et al., 2013). O sacro é constituído por 5 vértebras (S1 à S5), as quais até a juventude estão separadas, mas com o passar dos anos, através do processo de ossificação das cartilagens que as separa, elas se unem formando um único osso grande e triangular. Na parte inferior da coluna vertebral, na região caudal, está o cóccix que também possui 4 vértebras fundidas no formato triangular (COSTA et al., 2013).

As vértebras dessas cinco regiões são bem diferentes umas das outras, o que pode ser visualizado na Figura 3.

Figura 3 – Diferenciação das vértebras pelo formato.




Fonte: (MONJA, 2013).

Como pode-se analisar pela Figura 4a, as vértebras quando observadas nas vistas anatômicas<sup>1</sup> axial e coronal possuem formatos distintos, dependendo da região da coluna (cervical, torácica e lombar) que está sendo analisada, dando uma certa complexidade na criação de um padrão para detectá-las. Porém quando analisadas na vista sagital (Figura 4b), as vértebras das três regiões, citadas anteriormente, possuem um formato predominantemente retangular. Assim pelo fato de ser mais prático criar um padrão que encontre formas retangulares nas imagens, todas as imagens médicas que foram analisadas nesse trabalho representaram uma vista sagital (Figura 4b).


Figura 4 – Ilustração das vértebras nas três vistas anatômicas.

(a) Vistas **axial** e **coronal**

Fonte: (DREAMSTIME, 2017).

(b) Vista **sagital**

Fonte: Própria.



<sup>1</sup> As **vistas anatômicas** separam o corpo em 3 dimensões. **Sagital**: passa pelo corpo da frente para trás, dividindo ele em direita e esquerda, **axial**: passa horizontalmente pelo corpo, dividindo-o em parte superior e inferior, e **coronal**: passa pelo corpo de lado a lado, dividindo-o em frente e trás (BAILEY, 2017).

## 2.3 Modalidades de aquisição de imagens médicas


### 2.3.1 Radiografia

As radiografias (raios-X simples) são adquiridas por equipamentos constituídos por tubos de raios X, os quais emitem fótons que chocam-se contra um alvo metálico (WEBER; VILENSKY; CARMICHAEL, 2009). Os fótons de alta energia emitidos pela fonte de raio X podem ser absorvidos ou espalhados em diferentes graus conforme a densidade do tecido encontrado no caminho. Com isso os ossos que possuem uma densidade maior absorvem mais os raios X que os tecidos moles, resultando na radiografia diferentes tons de cinza, sendo que os ossos ficam mais claros, os tecidos em escalas de cinza e aqueles que quase não absorvem o raio X aparecem em preto na imagem.

Imagens radiográficas tradicionais são formadas pelos fótons que passam pelo corpo do paciente e se chocam com um receptor no plano oposto ao emissor. Esse receptor pode ser constituído de átomos de fósforo raro usado no filme radiográfico sensível a luz, ou ainda uma variedade de fotorreceptores que são utilizados na radiografia digital (MÉDICA, 2013). Devido a forma como o equipamento de raio X convencional é construído, as imagens geradas são imagens planas (2D) (GONZALEZ, 2010).

A Figura 5 apresenta a configuração básica dos equipamentos de radiografia, onde o colimador é a parte do equipamento que restringe o feixe, para acertar uma determinada região do corpo. A grade anti-difusora, diminui o número de raio X espalhado pelo tecido, causando os diferentes tons de cinza na imagem. O filme de raio-X, é responsável por armazenar a luz captada e conseqüentemente por gerar a imagem radiográfica.

Figura 5 – Configuração básica do equipamento de radiografia.




Fonte: (MÉDICA, 2013).

### 2.3.2 Tomografia Computadorizada (CT)

A Tomografia Computadorizada foi criada no início da década de 1970, por Godfrey N. Hounsfield e pelo professor Allan M. Cormack. A criação desta modalidade representou um dos episódios mais importantes na aplicação do processamento de imagens nos diagnósticos médicos. Esta técnica consiste de uma moldura circular ou de um anel rotatório que possui uma fonte de raio X de um lado e detectores de fótons no lado oposto. Este anel gira 360 graus ao redor do corpo do paciente, e conforme os raios X passam pelo paciente, eles vão sendo coletados pelos detectores correspondentes do anel (GONZALEZ, 2010). A medida que a fonte gira esse processo vai se repetindo, e as informações coletadas vão sendo transmitidas ao computador responsável pelo processamento das imagens, que vai construindo-as com os dados coletados. Através da movimentação do paciente em direção perpendicular ao anel de detectores, é possível obter uma série de “fatias”, que juntas formam uma imagem tridimensional (3D) do interior do paciente. Essas fatias podem variar de meio milímetro de espessura até 10 milímetros, dependendo do tipo de diagnóstico que deseja-se fazer. O espaçamento pequeno entre as imagens é necessário para manter uma relação espacial entre as imagens obtidas.

Nas radiografias tradicionais o feixe de raio X emitido é piramidal, enquanto que nas Tomografia Computadorizada (CT) é emitido um feixe em formato de leque através de uma pequena fenda (NUNES, 2006), como mostrado na Figura 6. Muitas vezes é necessário utilizar materiais de contrastes orais e/ endovenoso para melhorar os tons de cinza da imagem, que representam algumas partes do corpo do paciente (WEBER; VILENSKY; CARMICHAEL, 2009).

Figura 6 – Configuração básica do equipamento de tomografia computadorizada.



Fonte: (MEDICA, 2016).

Os valores obtidos depois do processamento são apresentados usando a escala de *Hounsfield*, a qual permite determinar o tipo de tecido em um determinado ponto da imagem. Tecidos com densidade maior que a água tem valores positivos e, os de densidade menor que a água tem valores negativos (NOBREGA, 2014). No caso deste trabalho é importante observar que na escala de *Hounsfield*, os valores para os tecidos ósseos variam entre 700 (osso esponjoso) até 3000 (osso denso) (SEERAM, 2009). Para outros tipos de tecidos e substâncias os valores estão resumidos na Tabela 1.

Tabela 1 – Escala de *Hounsfield*.

Substância	HU
Ar	-1000
Pulmão	-500
Gordura	-100 a -50
Água	0
Fluido cerebrospinal	15
Rim	30
Sangue	+30 a +45
Músculo	+10 a +40
Massa cinzenta	+37 a +45
Massa branca	+20 a +30
Fígado	+40 a +60
Tecidos moles, Contraste	+100 a +300
Osso	+700 (osso esponjoso) a +3000 (osso denso)

Fonte: (SEERAM, 2009).


### 2.3.3 Imagem por Ressonância Magnética (MRI)

A ressonância magnética é uma técnica que produz uma série de pulsos curtos e rápidos de Radiofrequência (RF) que são aplicados no paciente, sendo que os prótons de hidrogênio dos seus tecidos geram pulsos de "ecos" de RF que são detectados por receptores, os quais podem ser antenas de rádio. Estes sinais recebidos são processados para a formação das imagens seccionais do paciente, podendo posteriormente ser usadas para a geração de imagens bidimensionais e corte em qualquer plano de visualização (WEBER; VILENSKY; CARMICHAEL, 2009; GONZALEZ, 2010).

O equipamento de Imagem por Ressonância Magnética (MRI) contém um campo magnético gerado por um imã, que é responsável por polarizar e excitar os prótons de hidrogênio nas moléculas de água do tecido do paciente. Esse fenômeno está relacionado com a frequência de ressonância dos prótons que é de 42,58 MHz em um campo magnético de 1 Tesla (T) (VIEIRAI; OLIVEIRA; CARNEIRO, 2014). No equipamento é possível, através das antenas de RF, focar os pulsos emitidos na região que deseja-se investigar. Após serem captados pelos prótons esses pulsos produzem a mudança de direção nos *spin*,

alinhando-os com o campo magnético. Ao ser retirado o pulso de excitação, os prótons relaxam e retornam ao seu alinhamento inicial com o campo magnético do imã, e emitem pulsos de RF de "eco" (HAGE; IWASAKI, 2009). Um esboço geral de um equipamento de ressonância magnética é mostrado na Figura 7.

Figura 7 – Equipamento de ressonância magnética.



Fonte: (SCOPPETTA, 2016).

Tanto os equipamentos de CT e os de MRI produzem imagens bidimensionais de uma fina "fatia" do corpo do paciente. No entanto, ao contrário do CT, o MRI não utiliza radiação ionizante, diminuindo a exposição do paciente a radiação. Devido a grande quantidade de moléculas de água presente nos tecidos moles o MRI é mais indicado nestes exames (BOAVENTURA et al., 2017).

## 2.4 Padrão DICOM

Com a criação do equipamento da Tomografia Computadorizada (CT), e com o desenvolvimento tecnológico, várias modalidades de diagnósticos começaram a utilizar as imagens digitais (FICEL, 2006b). Assim o uso dos computadores em diagnósticos médicos passou a ser frequente, necessitando da criação de um conjunto de normas para padronizar o formato das imagens digitais geradas pelos diferentes equipamentos e também para uniformizar a comunicação entre eles. Este padrão criado foi denominado de DICOM (*Digital Imaging and Communications in Medicine*) (AZEVEDO-MARQUES; SALOMÃO, 2009).

O DICOM foi criado em 1983, por um comitê sediado nos Estados Unidos da América (EUA), formado pelo *American College Of Radiology* (ACR) e pela *National*



*Electrical Manufacturers Association* (NEMA) (FICEL, 2006b). Nesse tipo de padrão todos os exames médicos são armazenados em formato único, permitindo a troca de informações entre equipamentos de marcas e modalidades diferentes (e.g. CT e MRI). Isso torna possível a comunicação entre estes dispositivos, possibilitando a realização de diagnósticos longe dos aparelhos de aquisição de imagens (PIXEON, 2014).

Um arquivo DICOM é formado por um conjunto de dados de cabeçalho e pela imagem, empacotados em um único arquivo. Esses dados do cabeçalho estão organizados em uma série constante e padronizada de *tags*. Acessando os dados das *tags* é possível obter informações relativas à imagem, ao paciente, aos médicos envolvidos, aos procedimentos e as técnicas utilizadas para a aquisição da imagem médica. No Apêndice A foram ilustradas algumas *tags* DICOM.

Cada tipo de equipamento, dependendo da modalidade, possui uma determinada profundidade de *bits* por *pixel*, como pode ser analisado na Tabela 2. Mas a quantidade máxima suportada pelos arquivos DICOM é de 16 *bits* por *pixel*, no caso de imagens monocromáticas (DICOM, 2017).

Tabela 2 – Quantidade de *bits* por *pixel*, por modalidade.

Modalidade	<i>bits</i> por <i>pixel</i>
Radiografia	12
CT	12 - 16
MRI	16

Para a visualização do conteúdo de imagens DICOM faz-se necessário o uso de um visualizador DICOM. Para manipulação e análise das imagens médicas neste trabalho foi utilizado o *software* **GNU Octave**, junto com as funções '*dicomread()*' e '*imagesc()*' (disponíveis respectivamente nos pacotes '*dicom*' e '*image*'), para que fosse possível ler e visualizar as imagens médicas cedidas pela empresa Pixeon Medical Systems.

## 2.5 Algoritmos descritores de características

Os objetos em uma imagem podem possuir formas, cores e texturas, estas propriedades podem ser quantificadas e são conhecidas como características da imagem. As características por sua vez podem ser agrupadas em vetores, denominados de descritores da imagem (FALCAO, 2008). Este fato dos objetos poderem ser representados por vetores, possibilita o uso das ferramentas disponibilizadas pela álgebra linear.

Por isso, os métodos que realizam a detecção de objetos em uma imagem, na sua grande maioria, fazem uso de algoritmos descritores de características, para permitir o uso das técnicas de álgebra durante a procura pelos objetos.

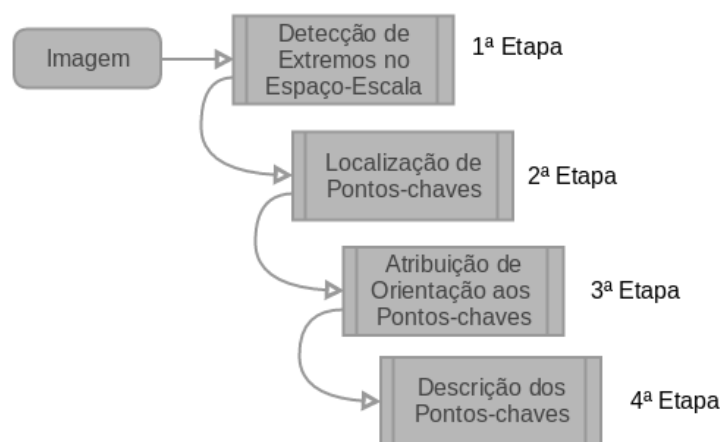
Neste trabalho são citados dois algoritmos descritores de características (SIFT e HOG), com uso potencial para tornar automático/semiautomático o processo de detecção das vértebras da coluna vertebral em imagens adquiridas em equipamentos de CT e MRI.

### 2.5.1 *Scale-Invariant Feature Transform (SIFT)*

Este algoritmo realiza a extração de características da imagem e foi proposto por David Lowe, em 1999. Ele é capaz de reconhecer e identificar objetos através de comparações, mesmo que os objetos tenham sofrido mudanças razoáveis na posição, rotação, iluminação e pequenas mudanças de perspectiva. O SIFT reconhece os objetos por partes, ou seja, por pontos-chaves (SILVA, 2014).

Para obter o descritor da imagem, o algoritmo SIFT pode ser dividido em 4 etapas, que estão ilustradas na Figura 8. Na primeira etapa (Detecção de Extremos) é realizado uma procura em todas as escalas e localizações da imagem, em busca de potenciais pontos de interesse invariáveis à escala e rotação. Isto é feito utilizando a função Diferença de Gaussianas (DoG) (SILVA, 2014). Na segunda etapa são localizados os pontos-chaves a partir dos pontos de interesse, encontrados na primeira etapa. Os pontos-chaves são os máximos e mínimos valores da imagem, adquiridos de uma subtração consecutiva dos *pixels* da imagem (SPERANDIO; SANTOS, 2011). Na terceira etapa é atribuído a orientação dos pontos-chaves, através dos gradientes locais da imagem, ou seja, é calculado um histograma de 36 intervalos (*bins*) a partir da orientação do gradiente de uma região de 16x16 *pixels*, com o centro em cada ponto-chave. Esta etapa faz com que os pontos-chaves sejam invariantes a rotação (LEON, 2012).

Figura 8 – Etapas do algoritmo SIFT.



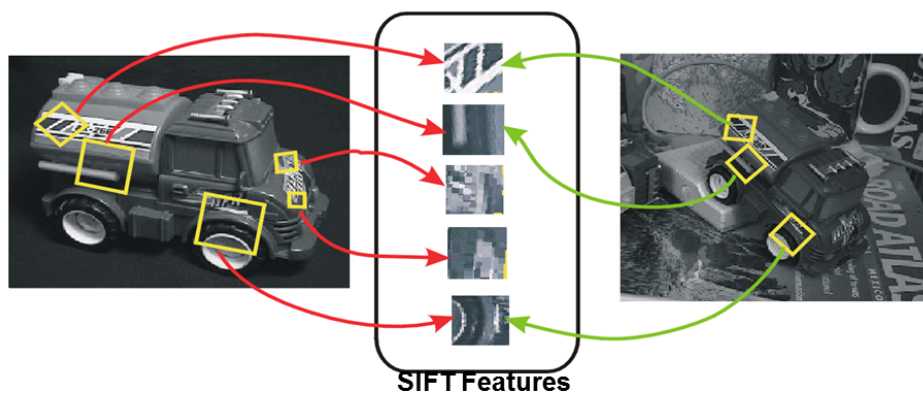
Fonte: Própria.

Na última etapa são construídos os descritores considerando uma região de tamanho 4 ao redor do ponto-chave, dividida em sub-regiões de 4x4 *pixels*. Para cada sub-região

é calculado um histograma com 8 orientações, criando um vetor de tamanho 128, para cada ponto-chave, baseado na magnitude e orientação dos gradientes (SILVA, 2014), (GHELLERE, 2015).

Assim ao final dessas etapas é obtido um descritor para cada ponto-chave, ou seja, uma imagem possui um conjunto de descritores e estes podem ser utilizados para fazer a comparação de uma imagem com outra. Esta comparação é baseada na distância euclidiana dos descritores (LEON, 2012). A Figura 9 ilustra o reconhecimento de um objeto e outra imagem que o possui, utilizando o SIFT.

Figura 9 – Reconhecimento de objetos em imagens, utilizando SIFT.



Fonte: (INTRINSICAL, 2014).

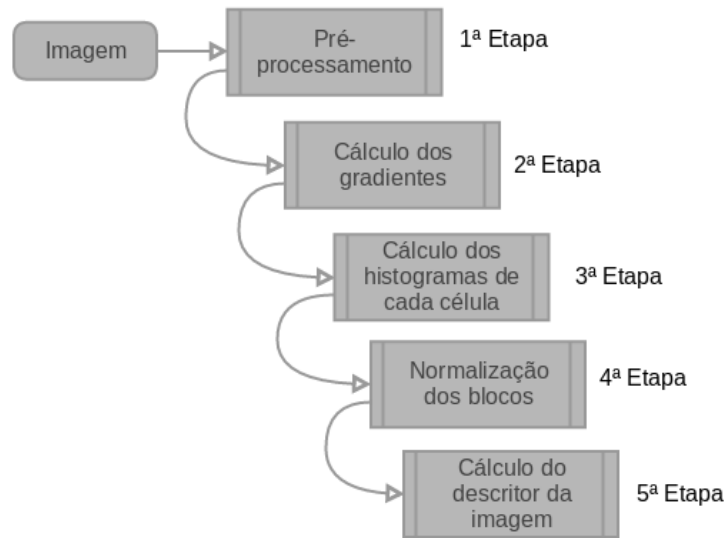
### 2.5.2 Histogram of Oriented Gradients (HOG)

É uma técnica de extração de características proposta por Dalal e Triggs (2005), baseada no algoritmo SIFT. No entanto o HOG diferencia-se do SIFT durante o cálculo dos histogramas de gradientes, no primeiro o cálculo é realizado em uma grade densa e sobreposta de células igualmente espaçadas na imagem, e no segundo os histogramas são calculados ao redor dos pontos-chaves (COSMO, 2014).

O algoritmo HOG descreve as bordas entre o objeto analisado e o fundo, através dos gradientes da imagem (COSMO, 2014). Para analisar a imagem em busca dos descritores é utilizado uma janela de detecção com um tamanho fixo, que percorre a imagem calculando um descritor HOG a cada posição da janela. Este descritor pode ser obtido em 5 etapas, ilustradas na Figura 10.

Na etapa de pré-processamento é realizado o corte e o redimensionamento da região que será analisada, para o mesmo tamanho da janela de detecção. Este tamanho varia de acordo com o que deseja-se analisar, por exemplo Santos (2013) utiliza uma janela de detecção com dimensões de  $128 \times 64$  pixels para auxiliar na detecção de pedestres, enquanto Lootus, Kadir e Zisserman (2013b) utiliza 4 dimensões diferentes de janela ( $48 \times 48$  px,  $48 \times 56$  px,  $48 \times 64$  px e  $48 \times 72$  px), durante a detecção de vértebras. A Figura 11 ilustra


Figura 10 – Etapas do algoritmo HOG.



Fonte: Própria.

a etapa de pré-processamento, durante um exemplo de detecção de vértebras em uma imagem.

Figura 11 – Exemplo da etapa de pré-processamento do HOG: (a) Imagem original, com uma região selecionada. (b) Corte da região selecionada (54x54 *px*). (c) Região redimensionada para um dos tamanhos da janela de detecção (48x48 *px*).




Fonte: Própria.

Na segunda etapa são calculados os gradientes em torno de cada *pixel*. Estes podem ser calculados com a filtragem da região, utilizando as máscaras  $[-1, 0, 1]$  para computar os gradientes horizontais e  $[-1, 0, 1]^T$  para os gradientes verticais (DALAL; TRIGGS, 2005). Com os vetores de gradientes da região computados é possível capturar os contornos e um pouco da textura da imagem.

Na terceira etapa são preparados os histogramas das orientações dos gradientes,

com as contribuições ponderadas das suas magnitudes as quais foram computadas no estágio anterior. Nesta etapa a janela de detecção é dividida em regiões espaciais menores de  $8 \times 8$  *pixels*, denominadas de células. Para cada um dos *pixels* da célula é capturada sua orientação e magnitude, armazenando-os em um histograma de 9 intervalos (*bins*) nas suas respectivas orientações, como pode ser observado na Figura 12. Dalal e Triggs (2005) demonstraram que o uso de até 9 *bins* tendo uma variação de  $0^\circ$  à  $180^\circ$  aumenta o desempenho do descritor.

Figura 12 – Criação dos Histogramas das células na terceira etapa do HOG.




Fonte: Adaptação de (CHENG et al., 2013).

A quarta etapa é destinada a normalização local dos histogramas considerando os valores de regiões espaciais denominadas de blocos. Esta etapa tem a função de minimizar os efeitos da variação de luminosidade e contraste do descritor (DALAL; TRIGGS, 2005). Cada bloco é formado por  $2 \times 2$  células, o equivalente a  $16 \times 16$  *pixels*. A forma usada para realizar a normalização dos blocos, consiste em concatenar os histogramas do bloco em um único vetor de 36 componentes (4 histogramas  $\times$  9 *bins*), e dividir seus valores pela sua magnitude, a qual é calculada pela norma do vetor de 36 componentes (COSMO, 2014; CERNA, 2014).

Esse processo de normalização repete-se para toda a janela de detecção, resultando em uma sobreposição de 8 *pixels* entre os blocos, levando cada célula da janela a pertencer a 4 blocos diferentes, com exceção das células das bordas, que pertencem a dois blocos, e dos cantos, que pertencem apenas um. Isto acaba ocasionando que cada célula seja normalizada em relação a diferentes blocos e aparecendo assim mais de uma vez no descritor final. Foi apresentado em Dalal e Triggs (2005) que esta redundância de informações aumenta o desempenho do descritor.

Essa sobreposição pode ser observada na Figura 13, onde estão ilustrados dois blocos sobrepostos em verde e azul, e os quadrados em vermelho representam as células da janela de detecção.

Figura 13 – Ilustração da sobreposição dos blocos na janela de detecção, durante a criação do descritor HOG.



Fonte: Própria.

Na última etapa é realizado a concatenação de todos blocos normalizados em um único vetor, resultando no descritor final do HOG.

## 2.6 Interpolador Bilinear

Durante a realização da ampliação, redução, rotação e correções geométricas de uma imagem é necessário utilizar um interpolador bidimensional, o qual permite aproximar valores posicionados em coordenadas fracionárias, em posições localizadas entre *pixels* da imagem original. Os três métodos de interpolação mais comuns são vizinhos próximos<sup>2</sup>, bilinear e bicúbica<sup>3</sup>. Nesta pesquisa será usado o interpolador bilinear, pois dentre os três é aquele que não provoca tantas distorções na imagem e não apresenta um custo computacional muito alto (GONZALEZ, 2010).

O interpolador bilinear realiza uma média ponderada das intensidades dos 4 vizinhos mais próximos da posição que deseja-se estimar (GONZALEZ, 2010). Para exemplificar os cálculos desse interpolador, será utilizado a Figura 14. Supondo que precisa-se estimar a intensidade ( $f(x, y)$ ) do ponto P, para isso aplicam-se duas interpolações lineares, uma na direção x e outra na direção y.


As Equações 2.1 e 2.2 estimam a interpolação linear na direção x, com elas tem-se a intensidade dos pontos  $R_1$  ( $f(x, y_1)$ ) e  $R_2$  ( $f(x, y_2)$ ). Com esses valores calculados, pode-se realizar a interpolação na direção y, conforme a Equação 2.3, e com isso obtém-se a

<sup>2</sup> **Interpolação por vizinhos próximos:** define a intensidade para cada nova posição, baseado no seu vizinho mais próximo da imagem original. Pode provocar distorções nas bordas (GONZALEZ, 2010).

<sup>3</sup> **Interpolação bicúbica:** utiliza os 16 vizinhos mais próximos para atribuir a intensidade do novo *pixel*, através de uma função com derivada contínua nestes pontos. A bicúbica consegue preservar os detalhes finos, porém tem um alto custo computacional (GONZALEZ, 2010).

intensidade de P ( $f(x, y)$ ) que desejava-se. A ordem das direções que é feita a interpolação não altera o resultado (GONZALEZ, 2010).

Figura 14 – Interpolação bilinear.



Fonte: (COMMONS, 2004).


$$f(x, y_1) \approx \frac{x_2 - x}{x_2 - x_1} f(Q_{11}) + \frac{x - x_1}{x_2 - x_1} f(Q_{21}) \quad (2.1)$$

$$f(x, y_2) \approx \frac{x_2 - x}{x_2 - x_1} f(Q_{12}) + \frac{x - x_1}{x_2 - x_1} f(Q_{22}) \quad (2.2)$$

$$f(x, y) \approx \frac{y_2 - y}{y_2 - y_1} f(x, y_1) + \frac{y - y_1}{y_2 - y_1} f(x, y_2) \quad (2.3)$$

Como os dois algoritmos citados nas seções anteriores (HOG e SIFT), analisam as regiões com tamanhos pré-definidos durante a criação dos seus descritores de características, é interessante que utilize um interpolador bilinear para estimar os *pixels* desconhecidos durante o processo de ampliação, redução e rotação da imagem. Um exemplo do uso do interpolador bilinear é no ajuste da região que deseja-se analisar na Figura 15a, onde o interpolador estima os *pixels* desconhecidos durante o processo de rotação e redução da região, para que seja possível obter a imagem alinhada e com as dimensões desejadas, como pode ser observado na Figura 15b.

Figura 15 – Exemplo de interpolação bilinear: (a) Imagem original (61x60 *px*). (b) Imagem rotacionada e redimensionada com interpolador bilinear (50x58 *px*).



Fonte: Própria.

## 2.7 Classificador

Um classificador gera um modelo capacitado a prever qual classe novas amostras pertencem. Esse modelo é gerado baseando-se em amostras que foram treinadas com classes rotuladas. Neste trabalho será abordado o classificador SVM.

### 2.7.1 *Support Vector Machine* (SVM)

Uma SVM é uma ferramenta utilizada em problemas de classificação treinada usualmente por uma técnica de aprendizagem de máquina supervisionada. Ela utiliza dados que foram previamente analisados e demarcados (a qual classe eles pertencem), de modo que na etapa de testes seja possível indicar a classe de novos dados. (VAPNIK, 1995).

As técnicas de aprendizagem de máquina supervisionadas possuem duas etapas: treinamento e avaliação. Na primeira etapa, no caso do treinamento de SVM, são utilizados os dados de entrada (vetores) mapeados em um espaço com  $n$ -dimensões e a SVM define qual hiperplano no espaço é capaz de separar os vetores de entrada em duas classes, com maior margem possível.


De acordo com CORTES e VAPNIK (1995) para definir o hiperplano ótimo faz-se necessário considerar apenas uma pequena quantidade dos vetores de entrada, chamados de vetores de suporte.

Comumente nas situações retiradas do mundo real esses vetores de suporte não são linearmente separáveis, como ilustrado na Figura 16. Sendo necessário o uso de alguma função Kernel (HERBRICH, 2001) que selecione esses vetores de suporte e projete-os em



uma dimensão maior do espaço, onde seja possível definir o hiperplano ótimo que separe os vetores de entrada em duas classes. Dentre as funções Kernel as mais utilizadas pelas SVMs são: linear, gaussiano e polinomial (CERNA, 2014; DETROZ, 2014). Neste trabalho foi utilizado a função Kernel linear L2-SVM (TANG, 2013) implementada em McCormick (2013), pois já era utilizada em implementações anteriores com bons resultados.

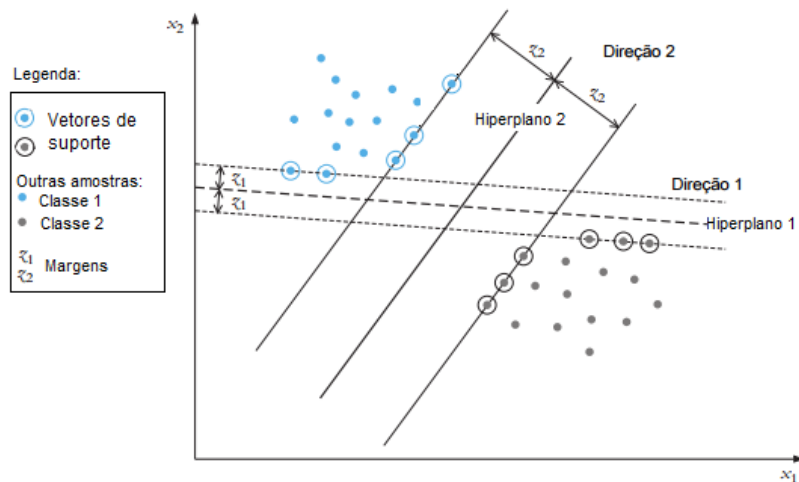
Figura 16 – Ilustração de classes não linearmente separáveis.



Fonte: (COSMO, 2014).

Ainda na etapa de treinamento, depois do uso da função Kernel obtém-se os vetores de suporte linearmente separáveis em alguma dimensão. No fim desta etapa a SVM definirá um hiperplano com margem máxima entre os vetores de suporte e que seja capaz de separá-los em duas classes. Na Figura 17 o hiperplano definido pela SVM seria o 2, pois ele é capaz de dividir as amostras em duas classes e por possuir a maior margem ( $2z_2$ ), entre as classes 1 e 2.

Figura 17 – Ilustração de dois hiperplanos que separam as amostras em duas classes.



Fonte: Adaptação de (COSMO, 2014).

Na etapa de teste o classificador recebe um vetor com um conjunto de dados com classe desconhecida, que passa pela função de decisão, a qual realiza um processamento algébrico com todos os vetores de suporte e baseado no resultado dessa função define-se de qual lado do hiperplano o vetor de entrada está. A função de decisão é mostrada na Equação 2.4,

$$f(X^T) = \sum_{i=1}^l y_i \alpha_i K(X_i, X_j) + b \quad (2.4)$$

onde  $X^T$  representa os dados de entrada do teste,  $l$  é o número de vetores de suporte,  $y_i$  é o rótulo da classe do vetor de suporte,  $\alpha_i$  e  $b$  são parâmetros encontrados durante o treinamento, e  $K(X_i, X_j)$  representa a função Kernel (CERNA, 2014).

## 3 Desenvolvimento

Este capítulo descreve o ambiente de desenvolvimento, os recursos e métodos utilizados neste trabalho, bem como uma visão geral do que foi desenvolvido e a metodologia adotada na detecção de vértebras em imagens médicas.

### 3.1 Ambiente de desenvolvimento

Para elaboração dos algoritmos e realização dos testes foi utilizado o *software* livre GNU Octave (EATON, 2017), versão 4.2.0. Optou-se por esse ambiente de trabalho por ser um *software* livre, além de proporcionar algumas facilidades, como a existência de pacotes para processamento de imagens, para manipulação de imagens médicas no padrão DICOM e por possuir funções que facilitam os testes e análise dos resultados. Adicionalmente tem-se a vantagem que o algoritmo HOG e o classificador SVM implementado por McCormick (2013) é compatível com o OCTAVE, o qual com pequenas modificações foi utilizado neste trabalho.

### 3.2 Base de dados de imagens

Todas as imagens utilizadas nesta pesquisa possuíam o formato DICOM, estavam devidamente anonimizadas e foram adquiridas do PACS<sup>1</sup> da empresa Pixeon Medical Systems, a qual cedeu os arquivos para este trabalho.

No Apêndice são mostradas as imagens que foram utilizadas no desenvolvimento deste trabalho. Sendo da "Imagem 1" até "Imagem 14" utilizadas no treinamento e da "Imagem de teste 1" até "Imagem de teste 4" usadas nos testes.

### 3.3 Técnicas usadas na detecção das vértebras

Para a identificação e classificação das regiões como vértebras ou não vértebras, optou-se em utilizar o algoritmo descritor de característica HOG aplicando-o para alimentar o classificador SVM. Esta escolha deu-se por eles serem mencionados de forma favorável no estado da arte de detecção de vértebras (SA et al., 2016; LOOTUS; KADIR; ZISSERMAN, 2013a) e por serem capazes de gerar bons resultados nas pesquisas desta área. Outro fator que influenciou nessa escolha é a disponibilidade da implementação do algoritmo HOG

<sup>1</sup> PACS - (*Picture Archiving and Communication System*) é o nome técnico para o sistema que realiza a digitalização, o compartilhamento e o armazenamento de imagens médicas provenientes dos exames realizados pelas diferentes modalidades de aquisição de imagens (PIXEON, 2015).

e do classificador SVM em McCormick (2013), com aplicação a detecção de pessoas. No trabalho citado, a janela de detecção tem uma característica vertical (16 células verticais x 8 células horizontais), enquanto que neste trabalho as características são horizontais, como observado na Figura 18, sendo necessário alterar as janelas de detecção para 6 células verticais e entre 6 e 9 células horizontais. A escolha dos tamanhos da janela de detecção: 6x6, 6x7, 6x8 ou 6x9, foram baseados no trabalho de Lootus, Kadir e Zisserman (2013b).

Figura 18 – Comparação das dimensões da janela de detecção.


(a) Janela de detecção de pessoas (16x8)

Fonte: (MCCORMICK, 2013).



(b) Janela de detecção de vértebras (Ex.: 6x8)

Fonte: Própria.




### 3.3.1 Implementação do Descritor HOG

Nessa subseção são apresentados os passos realizados na implementação do descritor HOG para este trabalho, utilizando como exemplo uma janela de detecção de 6x9 células conforme a Figura 19. Visando uniformizar a procura de diferentes tamanhos de janela, neste trabalho as células a direita são preenchidas com histogramas nulos quando a dimensão horizontal da janela de detecção é menor que 9 células.

Na primeira etapa da construção de um descritor HOG são calculados os gradientes de cada *pixel* da imagem realizando uma filtragem na região, utilizando as máscaras  $[-1, 0, 1]$  para computar os gradientes horizontais e  $[-1, 0, 1]^T$  para os gradientes verticais.

Na segunda etapa, baseando no gradiente de cada pixel são obtidos os histogramas para cada célula da janela de detecção, conforme o da Figura 20, armazenando nele a magnitude ponderada dos *pixels*. A ponderação é feita em relação a distância entre os dois centros de *bins* mais próximos do valor angular do gradiente. A equação 3.1 realiza a

Figura 19 – Ilustração da quantidade de células e *pixels* para demonstrar a criação do descritor HOG.




Fonte: Própria.

ponderação entre dois *bins*  $i$  e  $i+1$

$$W_i = 1 - \frac{|CB_i - \alpha|}{20} \quad (3.1)$$

onde  $\alpha$  é o valor angular do gradiente,  $CB_i$  são os centros dos *bins* mais próximos de  $\alpha$ , e  $W_i$  são as ponderações das magnitudes. Por exemplo, se um *pixel* tem orientação  $56^\circ$  e magnitude 100, é acrescido o valor 70 ao *bin* 3 ( $40^\circ - 59^\circ$ ) e 30 ao *bin* 4 ( $60^\circ - 79^\circ$ ).

Figura 20 – Ilustração dos histogramas utilizados para geração do descritor HOG.



Fonte: Própria.

A terceira etapa é o agrupamento de um conjunto de 2x2 células formando os blocos da imagem. A quarta etapa é a normalização dos histogramas de cada bloco, ou seja, são concatenados os histogramas das quatro células dentro do bloco em um vetor com 36 componentes (4 histogramas x 9 *bins*) e em seguida divide-se este mesmo vetor pela sua magnitude, a qual é calculada pela norma do vetor de 36 componentes acrescido de 0,01 para evitar a divisão por zero.

A última etapa consiste na concatenação de todos os histogramas normalizados dos blocos, resultando no vetor descritor HOG da imagem. Assim o descritor é composto por todos os valores normalizados dos histogramas que compõe a região analisada, a Figura 21 ilustra o vetor descritor da Figura 19, com um tamanho de 1440 (5 blocos x 8 blocos x 4 histogramas x 9 *bins*).

Figura 21 – Estrutura do descritor HOG.

0.283	0.165	0.087	0.416	0.267	0.023	. . .	0.157	0.556	0.618	0.036	0.211	0.053	0.088	
1														1440

Fonte: Própria.

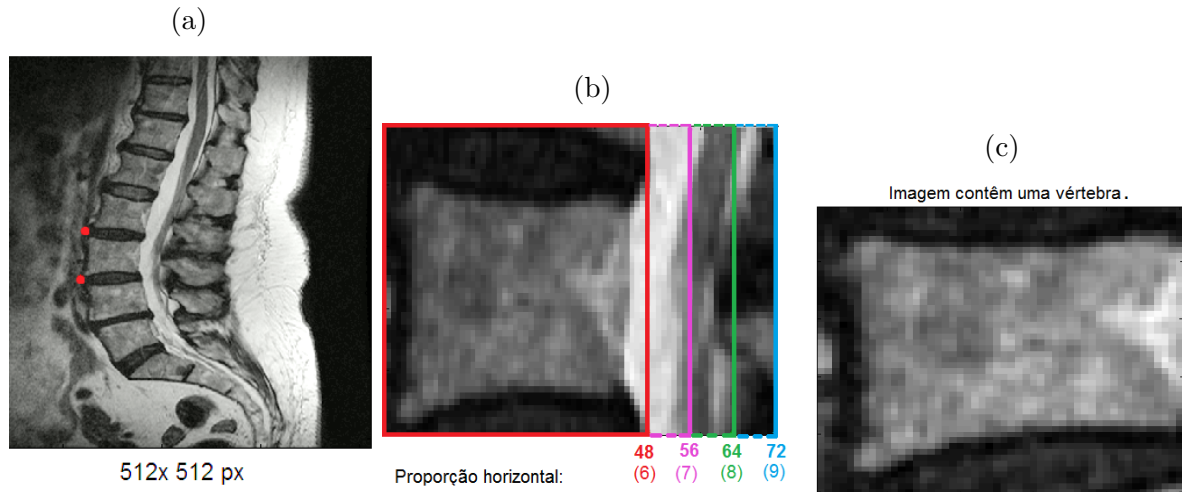
### 3.3.2 Treinamento da SVM

A fase de treinamento tem o propósito de criar um classificador binário, utilizando a ferramenta SVM, capaz de sinalizar se existe uma vértebra ou não em uma janela de tamanho fixo. Neste trabalho foram adotados 4 tamanhos de janela de detecção (48x48 *px*, 48x56 *px*, 48x64 *px* e 48x72 *px*) e consequentemente optou-se por realizar 4 treinamentos separados um para cada dimensão da janela, pois suas dimensões horizontais eram diferentes. Os treinamentos foram realizados em duas etapas: (1) seleção das imagens que seriam treinadas e (2) treinamento. Conforme mencionado anteriormente, a SVM utilizada nesse trabalho foi obtida da implementação de McCormick (2013).

Para a primeira etapa foi necessário a criação de uma ferramenta que realizasse o recorte e o redimensionamento das regiões retiradas das imagens DICOM. Esta ferramenta foi desenvolvida no Octave. Para auxiliar no redimensionamento da região, seja na ampliação, redução ou no ajuste das coordenadas da mesma foi utilizado a função de interpolação bilinear, implementada durante este trabalho também no Octave. A ferramenta funciona de forma iterativa, através da marcação com o ponteiro do mouse de dois pontos sobre a região que deseja-se retirar da imagem, a qual é redimensionada para a maior dimensão da janela detecção (48x72 *px*). Durante essa seleção o usuário pode escolher entre os quatro possíveis tamanhos de janela de detecção. Os procedimentos realizados pela ferramenta de recorte estão ilustrados na Figura 22.

Depois de redimensionar a região escolhida para uma das 4 dimensões da janela de detecção, armazenam-se em um arquivo todas as informações da região que serão utilizadas no treinamento, como por exemplo o nome da imagem de onde ela foi retirada, as suas coordenadas na imagem original e a proporção horizontal escolhida (6,7,8 ou 9).

Figura 22 – Etapas realizadas pela ferramenta de recorte: (a) 1º etapa - Seleção da região com dois pontos extremos a esquerda. (b) 2º etapa - Recorte da região selecionada e escolha da dimensão da janela de detecção. (c) Recorte da região na dimensão escolhida (48x48 *px*) e classificação se é ou não uma vértebra.



Fonte: Própria.

Na segunda etapa é realizado o treinamento de todas as imagens selecionadas, tanto das imagens identificadas como vértebras (positivas - 1) e não vértebras (negativas - 0). Para cada uma das imagens é aplicado o algoritmo HOG e são gerados os seus descritores. Em seguida os descritores são armazenados em vetores, juntamente com o rótulo (0 ou 1) da identificação dessa região. Esse processo repete-se para cada proporção de janela de detecção.

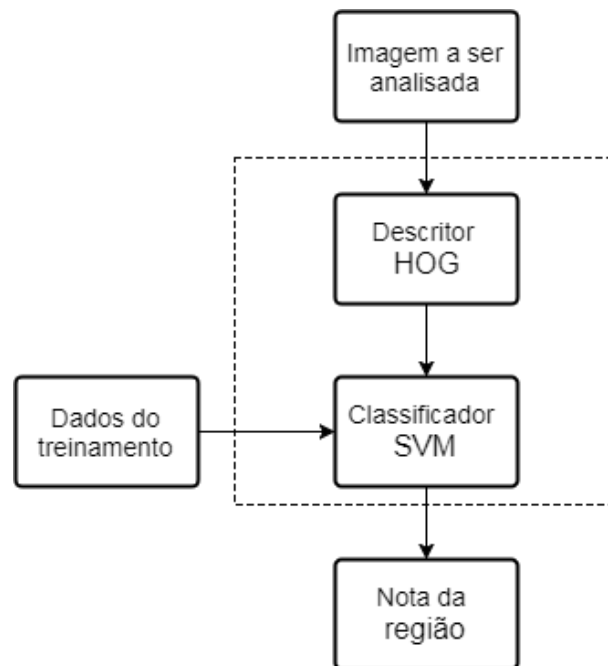
Para realizar os 4 treinamentos, cada uma das 4 proporções fornece separadamente para função SVM Linear os seus dois vetores: dos descritores e dos rótulos. Assim a função define com eles um hiperplano que separa as amostras em duas classes e retorna um vetor da normal a esse hiperplano, com o comprimento correspondente ao número de dimensões para representar a normal. Esse vetor é utilizado na fase de classificação de novas imagens.

### 3.3.3 Classificação das regiões testes

Na classificação são analisadas regiões que possuem as mesmas dimensões da janela de detecção, as quais não devem estar presentes no conjunto de regiões utilizadas no treinamento. Nesta fase o descritor HOG da região é extraído e apresentado ao classificador SVM, o qual realiza um produto escalar entre o descritor e o vetor normal obtido no treinamento. O resultado dessa operação será a distância da projeção do vetor descritor sobre o vetor normal. O valor dessa distância implica de qual lado do hiperplano a amostra está, e define a nota da região analisada. A metodologia é descrita em detalhes na Figura 23.

Em teoria, valores de nota maiores que 0 indicam que a imagem foi classificada

Figura 23 – Fase de classificação SVM.



Fonte: Própria.

como vértebra. No entanto, neste trabalho consideramos como vértebra apenas regiões que recebem nota superior a 0,4. Esse valor foi empiricamente escolhido, ou seja, durante o período de testes de imagens com o mesmo tamanho das janelas de detecção, as regiões que eram vértebras retornavam valores superiores a 0,4.

### 3.4 Métodos de procura das vértebras nas imagens


Utilizando a ferramenta descrita na subseção 3.3.3 é possível classificar manualmente as regiões da imagem como sendo vértebras e não vértebras. No entanto, o propósito desta pesquisa é determinar de forma automática as vértebras ao percorrer uma imagem da coluna vertebral. Assim, para alcançar o objetivo deste trabalho, foram implementados três métodos para percorrer as imagens com as janelas de detecção: um que realiza uma procura por toda a matriz dos histogramas normalizados e os outros dois utilizam heurísticas mais complexas. Antes de descrevê-los é necessário definir alguns termos e bases utilizadas na descrição dos métodos:

- As regiões analisadas são definidas por:
  - Um *topLeft* - coordenada (y,x) do canto superior esquerdo da região;
  - Uma proporção horizontal que varia entre 6 à 9 células e uma proporção vertical que é fixa de 6 células;



- Um ângulo de inclinação, que é fixo em 0 no Método 1 e nos Métodos 2 e 3 é variado;
- Uma escala que altera as dimensões da região. No Método 1 ela só é alterada no início, mas no 2 e 3 varia no meio do método.
- A matriz dos histogramas normalizados é percorrida por janelas de detecção com as seguintes proporções verticais x horizontais de células, respectivamente: 6x6, 6x7, 6x8 e 6x9.
- Quando uma região é identificada pelo classificador SVM como vértebra, ela é destacada na imagem original com o contorno de um retângulo. Para facilitar a análise visual, a cor da borda indica a faixa de valores das notas do classificador SVM, conforme indicado na Figura 24.

Figura 24 – Cores dos retângulos com suas respectivas notas do classificador.



Fonte: Própria.

Antes de iniciar o processo de classificação em qualquer um dos 3 métodos, a imagem DICOM tem a sua escala ajustada de acordo com a Equação 3.2

$$AjustEscala = \frac{HightJanela * pxMm(1)}{HightVet} * 100 \quad (3.2)$$

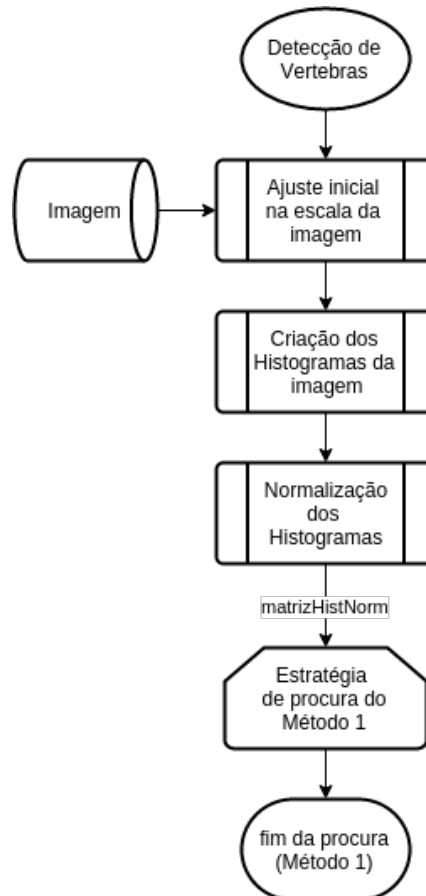
onde o valor da variável  $pxMm$  é obtido da própria imagem, na sua *tag* DICOM chamada de *PixelSpacing*, esta informa quanto que 1 *pixel* da imagem equivale em milímetros. O valor da variável *HightJanela* é sempre 48, pois equivale a altura da janela de detecção. No entanto a variável *HightVet* representa a altura da vértebra e esta como visto na seção 2.2 varia de tamanho de acordo com a região que será analisada, por exemplo as vértebras cervicais são menores que as lombares. Tendo esse conhecimento, foi necessário medir a dimensão vertical de um conjunto de vértebras com auxílio de uma ferramenta radiológica, e assim determinar o valor aproximado da altura das vértebras em cada uma das regiões (cervical, torácica e lombar) da coluna vertebral. Para vértebras lombares o valor foi de 28 milímetros (mm). Assim antes de realizar o ajuste da escala, é solicitado que seja informado a região que está sendo exibida na imagem (cervical, torácica ou lombar), para poder retornar o valor da escala estimado pela Equação 3.2.

### 3.4.1 Método 1

O Método 1 para percorrer a imagem realiza uma busca em todas as células, ou seja, para cada imagem analisada são preparados os seus histogramas normalizados das células e estes são percorridos pelas janelas de detecção em busca de vértebras. Essa busca é realizada deslocando a janela de detecção de 1 em 1 célula, tanto na direção horizontal como na vertical.

A metodologia adotada para esse método está exemplificada na Figura 25. A primeira etapa realizada é o ajuste inicial na escala da imagem. Em seguida com auxílio do interpolador bilinear é feito o redimensionamento da imagem com a escala obtida, para que as vértebras da imagem estejam aproximadamente proporcionais as janelas de detecção, facilitando sua identificação.

Figura 25 – Fluxograma do Método 1.



Fonte: Própria.

Na segunda etapa são preparados os histogramas de todas as células da imagem e na terceira etapa são formados os blocos e seus histogramas são normalizados. Os histogramas normalizados são armazenados em uma matriz (*matrixHistNorm*) e por fim, é percorrido esta matriz em busca de regiões que sejam identificadas pelo classificador SVM como vértebras.

A Listagem E.1 do Apêndice E, apresenta o pseudocódigo da estratégia de procura adotada no Método 1. Neste método, a matriz dos histogramas normalizados (*matrizHistNorm*) é percorrida em todas as 4 proporções de janela de detecção. A cada nova região presente na janela de detecção é chamado a função *selecionaHists*, a qual recebe como parâmetro a matriz e as coordenadas da região e retorna os histogramas dessa região concatenados em um vetor descritor (*regiaoAnalisar*) na mesma dimensão da janela. Em seguida este vetor é fornecido para a função *ClassificadorSVM*, que realiza a classificação da região com uma nota (*notaP*). Caso a *notaP* seja superior a 0,4 a região é considerada vértebra sendo destacada na imagem original com retângulo ao seu redor, com a cor relacionada à *notaP*.

Durante a implementação desse método realizou-se um estudo para reduzir o espaço de procura na imagem, para que a busca por vértebras ocorresse apenas na parte central onde normalmente a coluna vertebral é projetada. No entanto, ao analisar algumas imagens percebeu-se que as vértebras as vezes estão mais a esquerda ou a direita da imagem, assim essa restrição do espaço de procura foi descartada e adotou-se a imagem inteira como espaço de procura no Método 1.

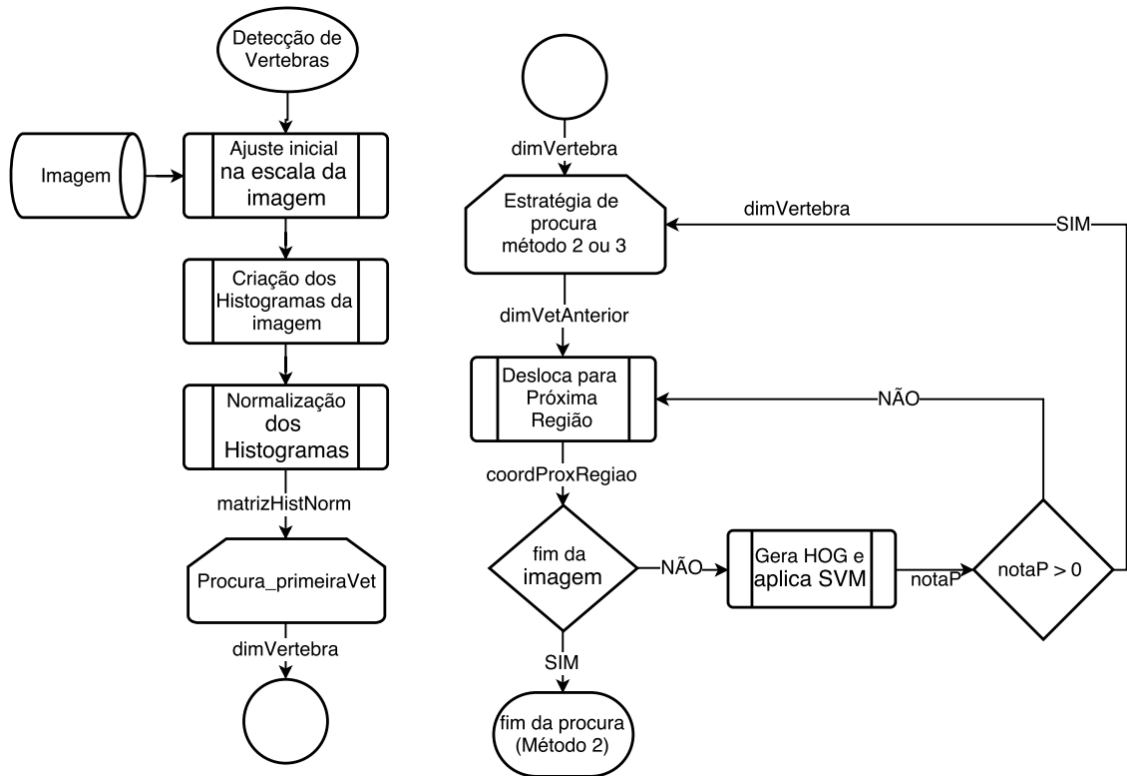
### 3.4.2 Método 2

O Método 2 foi elaborado, pois com o Método 1 não era possível encontrar vértebras que estavam inclinadas na imagem. Dessa forma, incluiu-se um ângulo de rotação da região analisada para melhorar a procura. Também foi necessário alterar a forma como iria-se percorrer a imagem em busca das vértebras, pois realizar uma busca exaustiva em variações menores que 8 *pixels*, com variação no ângulo de rotação tornaria o método muito lento. Assim, no Método 2 apenas a primeira vértebra é detectada com a estratégia de procura do Método 1, mas as demais são encontradas considerando a relação de proximidade entre as vértebras. A metodologia adotada para esse método está exemplificada na Figura 26.

As primeiras etapas desse método são iguais as do Método 1. No entanto, após encontrar a primeira vértebra, uma nova estratégia de procura é utilizada. Nela é realizado um refinamento nos parâmetros da vértebra encontrada, deslocando-se o seu *topLeft*, variando sua proporção horizontal, sua escala e seu ângulo de inclinação, visando melhorar a nota obtida pelo classificador SVM.

O pseudocódigo da Listagem E.2 do Apêndice E, descreve o algoritmo de procura implementado para o refinamento dos parâmetros. A estratégia de procura do Método 2 tem como característica: (1) realizar inicialmente a variação do ângulo de inclinação, de -12° à 12° em passos de 3°; (2) variar em seguida a escala da imagem de 90% à 110% em passos de 5%; (3) variar a proporção horizontal da janela de detecção de 6 até 9 células; (4) por último são deslocados a origem *TopLeft* na direção vertical e na direção horizontal, ambos de -8 à 8 *pixels* em passos de 4 *pixels*.

Figura 26 – Fluxograma dos Métodos 2 e 3.



Fonte: Própria.

Os limites e passos para a variação dos parâmetros foram determinados de modo que as notas do classificador SVM pudessem se aproximar de 0,9.

A rotação das coordenadas da região analisada é efetuada com o auxílio da matriz de rotação  $\begin{pmatrix} \cos(\alpha) & \sin(\alpha) \\ -\sin(\alpha) & \cos(\alpha) \end{pmatrix}$ , onde  $\alpha$  é o ângulo de inclinação da imagem em relação a horizontal. Ao realizar a rotação de uma região, ela sempre é feita tendo o centro da janela de detecção como *pivot*.


Em qualquer etapa do refinamento dos parâmetros, a procura é interrompida se a nota do classificador SVM for superior a 0,9, pois esta nota indica que a vértebra foi identificada com um bom ajuste dos parâmetros: ângulo de inclinação, proporção da janela de detecção, escala, posição horizontal e vertical.

Se após variar todos os parâmetros entre seus limites máximos e mínimos, não for encontrada nenhuma região com nota superior a 0,9, adota-se como a posição da vértebra a região que resultou na maior nota, desde que essa seja superior a 0,5. Esse limiar foi adotado para reduzir os falsos positivos.

Após realizar o refinamento da primeira vértebra é deslocado para próxima região que será analisada. A Figura 27 ilustra um exemplo da área de procura para a próxima

região, ou seja, é considerado as dimensões da vértebra anterior, efetua-se o salto para a próxima posição de origem de procura (*TopLeft*). O salto possui o comprimento da última vértebra mais 3% desse mesmo comprimento e este é dado na mesma direção da inclinação da vértebra anterior, tanto para cima quanto para baixo. A região que originou desse salto terá um novo *topLeft*, mas as demais dimensões serão iguais da vértebra anterior (mesma inclinação, mesma escala das dimensões e mesma proporção horizontal). Em seguida, analisa-se a nota gerada pelo classificador, se ela for superior a zero é feito o refinamento da região para buscar os parâmetros que resultem em uma nota do classificador maior que 0,9. Caso a nota seja menor do que zero, é acrescido mais 3% ao salto.

Figura 27 – Exemplo da área de procura do Método 2, após encontrar a primeira vértebra.



Fonte: Própria.

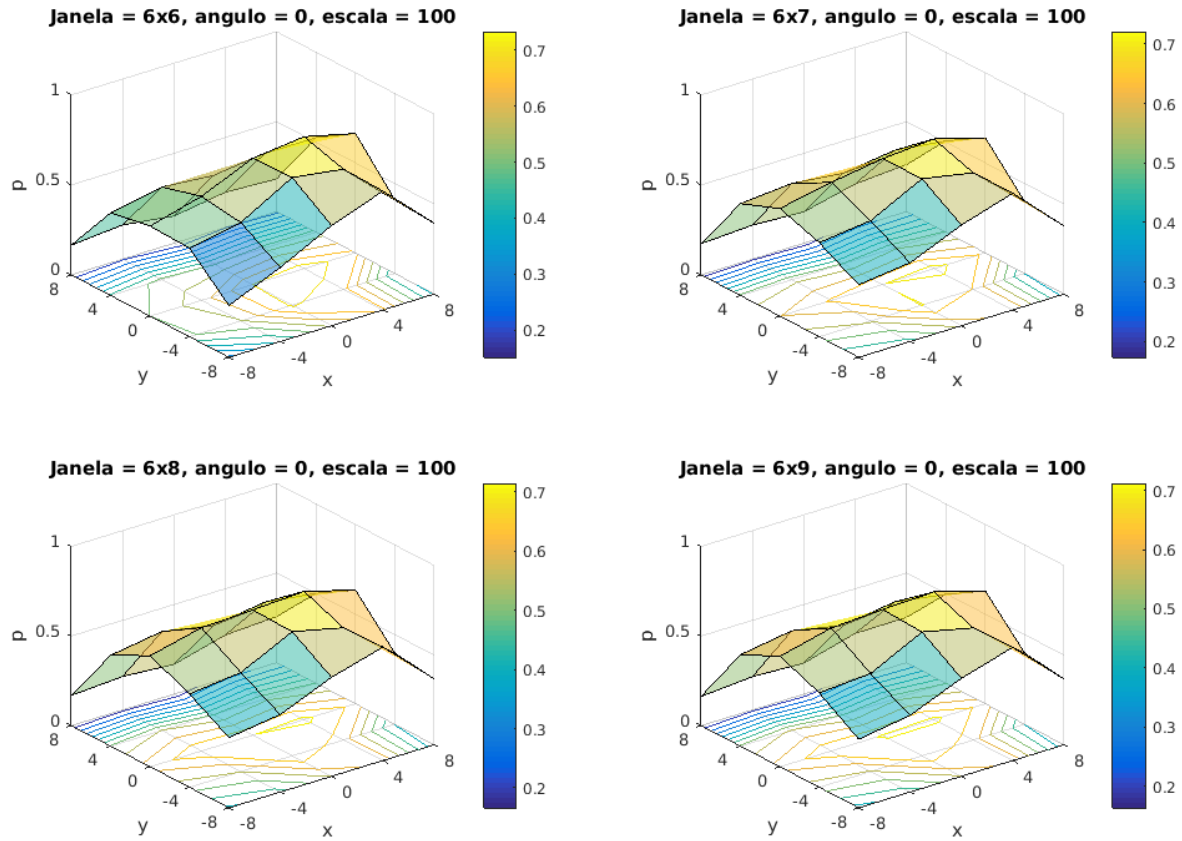
Inicialmente a procura pelas demais vértebras da imagem é feito acima da primeira vértebra encontrada, mas assim que a janela de detecção atingir o topo da imagem, retorna-se para a primeira região detectada e continua-se a percorrer a imagem abaixo desta região. Cada vértebra detectada durante o processo de procura é destacada na imagem com um retângulo colorido, cuja a cor indica a faixa da nota obtida do classificador SVM.

### 3.4.3 Método 3

Com o Método 2 de procura é possível detectar a maioria das vértebras presentes nas imagens de testes, porém apresenta um alto custo de processamento. Dessa maneira, foi realizado uma análise nas notas obtidas durante uma procura exaustiva de uma vértebra com o Método 2, ilustrada na Figura 28, variando os 5 parâmetros da região até os seus limites. Assim, percebeu-se que o fator predominante para obter notas maiores é a variação da posição do *topLeft*(y,x) seguido da variação do ângulo de inclinação. Os parâmetros proporção e escala da janela de detecção mostraram ter uma menor influência na nota.

Dessa forma, foi proposta uma estratégia de procura (Método 3) semelhante ao Método 2, Figura 26, mas modificando a ordem de refinamento dos 5 parâmetros.

Figura 28 – Análise das notas obtidas com o Método 2, variando os 5 parâmetros de uma região analisada.



<sup>2</sup>Janela: proporção da janela de detecção. <sup>3</sup>Ângulo e escala: inclinação e escala da janela de detecção.

Fonte: Própria.

Na estratégia de refinamento do Método 3, mostrada na Listagem E.3 do Apêndice E, tem como características: (1) Primeiramente desloca-se a origem (*TopLeft*) na direção vertical e na direção horizontal (de -8 à 8 *px*, em passos de 4 *px*); (2) Em seguida varia-se o ângulo de inclinação (de -12° à 12°, em passos de 3°), juntamente realiza-se um ajuste fino na posição do *topLeft* (de -2 à 2 *px*, em passos de 2 *px*); (3) Por fim, varia-se a escala (de 90% à 110%, em passos de 5%) e a proporção horizontal da janela de detecção (de 6 até 9 células). Os critérios de parada do algoritmo de refinamento são os mesmo do Método 2.

A seleção da próxima região de procura e a finalização da procura pela imagem são realizadas da mesma forma que no Método 2, conforme mostra a Figura 26.

## 4 Resultados

Nessa seção será apresentado o ambiente de trabalho onde os resultados foram obtidos, as imagens utilizadas no treinamento da SVM e nos testes de classificação, bem como os resultados de desempenho em termos de vértebras encontradas e tempo de procura para os três métodos descritos no Capítulo 3.

### 4.1 Ambiente de trabalho

Como os resultados de complexidade dos algoritmos estão de certa forma relacionados com o sistema operacional, *software* utilizado e computador, descreve-se aqui o ambiente de trabalho utilizado. O *software* utilizado foi o Octave versão 4.2.0, incluindo o pacote (pkg) DICOM. A configuração de *hardware* e sistema operacional do computador utilizado é mostrado na Tabela 3.

Tabela 3 – Especificação do computador utilizado para adquirir os resultados.

Sistema			
Operacional	Processador	Memória (RAM)	Tipo de sistema
Windows 10	i5-4210U CPU @ 1.70 GHz 2.40 GHz	8 GB	64 bits

### 4.2 Treinamento da SVM

Para realizar os quatro treinamentos, um para cada proporção horizontal (6, 7, 8 e 9), foram utilizadas 14 imagens médicas da coluna vertebral. Sendo de cada uma delas retiradas 10 regiões, totalizando 140 regiões de imagem para o treinamento. A Tabela 4 informa o número de imagens positivas (vértebras) e negativas (não vértebras), com que cada treinamento foi realizado.

Tabela 4 – Número de regiões treinadas em cada proporção.

Proporção (Vertical:Horizontal)	Regiões Positivas	Regiões Negativas
6:6	26	18
6:7	29	18
6:8	9	18
6:9	6	16

No Apêndice C as 14 imagens e as regiões utilizadas nos treinamentos estão destacadas, na qual os retângulos tracejados em vermelho representam as regiões que foram treinadas como não vértebras e em verde como vértebras. As especificações das imagens e o número de regiões positivas e negativas retiradas de cada imagem é apresentada na Tabela 5.

Tabela 5 – Especificações das imagens treinadas.

Imagem	Modalidade de Aquisição	Região da Coluna Vertebral	Número de Regiões Positivas	Número de Regiões Negativas
1	CT	Torácica	5	5
2	CT	Lombar	5	5
3	MR	Lombar	5	5
4	MR	Lombar	5	5
5	MR	Cervical	5	5
6	MR	Torácica	5	5
7	MR	Cervical	5	5
8	CT	Lombar	5	5
9	CT	Torácica	4	6
10	CT	Lombar	4	6
11	MR	Cervical	6	4
12	CT	Cervical	4	6
13	CT	Cervical	7	3
14	MR	Torácica	5	5

O tempo total de treinamento do classificador SVM, após terem sido selecionadas manualmente as 140 regiões destacadas no Apêndice C, foi de 1,743 minutos.

### 4.3 Métodos de procura na imagem

Para avaliar o desempenho dos três métodos de procura automática de vértebras, foram utilizadas 4 imagens DICOM de coluna vertebral, que não haviam sido utilizadas na fase de treinamento. Essas imagens de teste estão apresentadas no Apêndice D e algumas de suas características estão apresentadas na Tabela 6. As características consideradas são: a modalidade usada na aquisição de cada uma, a região da coluna que elas exibem, o ajuste inicial necessário na escala, bem como o valor da *tag* DICOM (*PixelSpacing*) utilizada para calcular esse ajuste inicial.



Tabela 6 – Informações das imagens utilizadas nos testes.

Imagem	Modalidade de aquisição	Região da Coluna Vertebral	Ajuste na Escala Inicial	PixelSpacing
1	MR	Lombar	177 %	[1,0312; 1,0312]
2	MR	Lombar	94 %	[0,5469 ; 0,5469]
3	MR	Lombar	100 %	[0,5859; 0,5859]
4	CT	Lombar	45 %	[0,3183; 0,3183]


Apesar de terem sido obtidos os resultados para todas as imagens, nas subseções seguintes foram apresentados com detalhes apenas os resultados para a imagem de teste 1. Os resultados obtidos para as imagens de teste 2, 3 e 4 com os três métodos de procura, são apresentados respectivamente no Apêndice F, Apêndice G e Apêndice H.

Nas imagens que ilustram os resultados obtidos nos três métodos, cada região encontrada foi destacada com um retângulo colorido e identificada por um número, que corresponde a ordem com que as detecções foram realizadas. A cor dos destaques, está relacionada com a nota obtida do classificador SVM para cada região, como mencionado na seção 3.4.

#### 4.3.1 Método 1

Aplicando o primeiro método de procura na imagem de teste 1 foi possível identificar algumas regiões, as quais classificadas pela SVM com notas superiores a 0,4. Cada região encontrada aparece destacada na Figura 29. Os detalhes de cada uma estão apontados na Tabela 7.

Figura 29 – Vértex detectadas na imagem de teste 1, com o Método 1.



<sup>1</sup>Os retângulos indicam as regiões detectadas. <sup>2</sup>As cores indicam as faixas de notas do classificador. <sup>3</sup>Os números indicam a ordem de procura. <sup>4</sup>A região 16 representa um falso positivo.

Tabela 7 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 1. Imagem de teste 1.

Região	Proporção Horizontal	TopLeft (y,x)	Nota classificador SVM (notaP)
1	6	(32, 376)	0,48863
2	7	(72, 376)	0,42762
3	6	(80, 368)	0,57606
4	7	(80, 376)	0,64144
5	7	(80, 384)	0,44062
6	7	(88, 368)	0,50755
7	7	(88, 376)	0,52368
8	8	(120, 360)	0,42310
9	6	(120,368)	0,58130
10	7	(128, 368)	0,45508
11	7	(280, 320)	0,62256
12	7	(280, 328)	0,55199
13	6	(328, 320)	0,52101
14	7	(336, 312)	0,74064
15	6	(336, 320)	0,91675
16	6	(488, 264)	0,47379
<b>Média</b>			<b>0,5557</b>

A Tabela 8 informa os tempos despendidos em cada uma das etapas do Método 1

para as quatro imagens testes. Nesta tabela pode-se observar que o tempo total do Método 1 para a imagem de teste 4 foi menor que os demais, isto é consequência de a imagem mostrar apenas 4 vértebras e possuir dimensões menores que as outras. Também é possível perceber na Tabela 8 que a etapa de procura na matriz de histogramas é aquela que utiliza mais tempo no Método 1, cerca de 90%.

Tabela 8 – Tempos em minutos utilizados nas etapas do Método 1.

Imagem	Ajuste na escala inicial	Criação e normalização dos histogramas	Procura por vértebras	Total do método
1	0,87467	0,52584	12,668	14,068
2	0,65694	0,36820	9,0628	10,087
3	0,73858	0,41721	10,326	11,481
4	0,16560	0,083318	1,2372	1,4860

Para averiguar quais as funções que utilizam mais tempo de processamento e são chamadas em maior número de vezes, foi utilizada a ferramenta **profile** do Octave. Assim constatou que o processo de interpolação bilinear utilizado no recorte e no redimensionamento da região analisada, é o de maior custo computacional do método.

Como exemplificado na Figura 29 e nas imagens do Apêndice F, nesse método detectou-se apenas vértebras que estavam com um ângulo de inclinação próximo ao zero, com isso vértebras com inclinação maior não foram identificadas. Além disso, vértebras sobrepostas foram encontradas e algumas regiões foram identificadas erroneamente como vértebras (falsos positivos), ver nas figuras 29, 39 e 41. O resumo dos resultados obtidos com as 4 imagens de teste é mostrado na Tabela 9.

Tabela 9 – Detalhes das classificações nas imagens teste utilizando o Método 1.

Imagens	Vértebras na Imagem	Classificações feitas	Vértebras Encontradas	Falsos Positivos	Falsos Negativos	Média das notas do classificador	Número de chamados do classificador	Tempo Total de Procura (min)
1	8	16	5	1	3	0,5557	13570	14,068
2	7	12	5	1	2	0,4789	8188	10,087
3	7	2	1	0	6	0,4750	9700	11,481
4	3	6	3	1	0	0,5400	1560	1,486


<sup>5</sup>Classificações feitas: Número de vezes que o classificador SVM identificou uma região como vértebra.

### 4.3.2 Método 2

Com intuito de identificar as vértebras independente da sua inclinação na imagem, desenvolveu-se o Método 2 e o aplicou as mesmas imagens testes. As vértebras identificadas na imagem de teste 1 são mostrados na Figura 30. Nesta figura e nas imagens do Apêndice G, o retângulo com borda tracejada dentro da região indicada com o número 1 ilustra a região da primeira vértebra encontrada com a primeira etapa de procura pela matriz

dos histogramas normalizados, antes do refinamento. Os retângulos com borda contínua representam as regiões identificadas após cada etapa de refinamento. Os parâmetros e resultados obtidos em cada região ilustrada na Figura 30 são mostrados na Tabela 10.

Figura 30 – Vértex detectadas na imagem de teste 1, com o Método 2.



<sup>6</sup>Os retângulos indicam as regiões detectadas. <sup>7</sup>As cores indicam as faixas de notas do classificador. <sup>8</sup>Os números indicam a ordem de procura.

Tabela 10 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 2. Imagem de teste 1.

Região	TopLeft (y,x)	Escala	Proporção Horizontal	Ângulo de inclinação	Nota obtida do Classificador (SVM)	Tempo de Procura (min)
1	( 24,81, 364,93)	105 %	6	-3	0,57003	61,532
2	(74,64, 373,96)	85 %	7	3	0,87001	61,347
3	(115,47,367,37)	105 %	7	6	0,92682	7,6340
4	(162,14, 358,74)	100 %	7	9	0,94630	32,180
5	(215,38, 345,17)	95 %	7	3	0,92638	51,123
6	(267,62, 322,72)	110 %	7	-9	0,90271	26,155
7	(324,66, 311,04)	100 %	7	-9	0,93084	25,929
8	(388,14 , 312,95)	105 %	6	-12	0,72585	60,227
<b>Média</b>					<b>0,8498</b>	<b>40,7659</b>

A Tabela 11 mostra o resumo dos resultados da aplicação do Método 2 nas 4 imagens de teste. Os resultados mostram que a aplicação desse método nas imagens testes permitiu detectar todas a vértebras projetadas na imagem, exceto na imagem de teste 3 (Figura 43) na qual uma vértebra não foi detectada. Contudo, é importante destacar que

o tempo utilizado na identificação das vértebras foi muito longo, na ordem de centenas de minutos.


Tabela 11 – Detalhes das classificações nas imagens teste utilizando o método 2.

Imagens	Vértebras na Imagem	Vértebras Encontradas	Falsos Positivos	Falsos Negativos	Média das notas do classificador	Número de chamados do classificador	Tempo Total de Procura (min)
1	8	8	0	0	0,8498	29069	326,311
2	7	7	0	0	0,8595	27995	317,902
3	7	6	0	1	0,7076	32428	361,691
4	3	3	0	0	0,9054	10332	115,131

### 4.3.3 Método 3

Com o objetivo de reduzir o tempo de procura na identificação de todas as vértebras das imagens de teste, foi desenvolvido o Método 3. Ao submeter as 4 imagens de testes ao método foram detectadas as mesmas regiões de vértebras que no Método 2, conforme mostra a Figura 31. Os parâmetros e resultados obtidos em cada região ilustrada na Figura 31 são mostrados na Tabela 12.

Figura 31 – Vértebras detectadas na imagem de teste 1, com o Método 3.



<sup>9</sup>Os retângulos indicam as regiões detectadas. <sup>10</sup>As cores indicam as faixas de notas do classificador. <sup>11</sup>Os números indicam a ordem de procura.

Tabela 12 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 3. Imagem de teste 1.

Região	TopLeft (y,x)	Escala	Proporção Horizontal	Ângulo de inclinação	Nota obtida do Classificador (SVM)	Tempo de Procura (min)
1	(27,289 , 364,77)	100 %	6	-3	0,60827	1,4234
2	(74,36 , 373,98)	95 %	7	3	0,83721	1,3947
3	( 114,68 , 366,51)	100 %	7	6	0,92207	0,69662
4	(162,62 , 354,46)	100 %	7	6	0,91622	0,80027
5	(211,68 , 340,13)	100 %	7	3	0,90778	0,44519
6	( 271,62 , 321,92)	100 %	7	-6	0,94372	0,66880
7	(329,30 , 310,72)	100 %	7	-9	0,99362	1,0462
8	(390,64 , 313,86)	110 %	6	-12	0,67601	1,4457
<b>Média</b>					<b>0,8506</b>	<b>0,9901</b>

A Tabela 13 mostra o resumo dos resultados da aplicação do Método 3 nas 4 imagens de teste. Os resultados mostram que a aplicação desse método nas imagens testes permitiu detectar todas as vértebras projetadas na imagem, além de detectá-las com um tempo de procura muito menor que com o Método 2.

Tabela 13 – Detalhes das classificações nas imagens teste utilizando o método 3.

Imagens	Vértebras na Imagem	Vértebras Encontradas	Falsos Positivos	Falsos Negativos	Média das notas do classificador	Número de chamados do classificador	Tempo Total de Procura (min)
1	8	8	0	0	0,8506	755	8,074
2	7	7	0	0	0,8563	735	8,118
3	7	7	0	0	0,6641	905	11,071
4	3	3	0	0	0,8881	336	3,297

## 4.4 Análise dos resultados

Nas subseções anteriores, percebeu-se que o Método 3 obteve resultados melhores que os métodos 1 e 2, tanto em termos de número de vértebras encontradas, falsos positivos e negativos, e também no tempo de procura.

Conforme já mostrado o Método 1 detectou apenas vértebras que estavam com inclinação próxima a zero nas imagens de teste, consequentemente apresentou o maior índice de falsos negativos em relação aos demais. Apesar desse método não apresentar bons resultados, ele possibilitou criar o ponto de partida (primeira vértebra) para a procura das demais vértebras nos métodos 2 e 3.

Os resultados do Método 2 foram satisfatórios em termos das vértebras encontradas através do refinamento proposto nesse método, pois foi possível obter notas maiores durante a classificação e a partir da estratégia de procura adotada encontrou a maioria das vértebras nas imagens de teste. Além disso, conseguiu-se diminuir o índice de falsos positivos, pelo fato de realizar uma busca em regiões mais restritas que Método 1. Acredita-se que o falso

negativo encontrado no Método 2 possa ser resultado de: (1) a vértebra da imagem estava com inclinação muito diferente da utilizada na procura; (2) O deslocamento da janela foi inferior ou superior ao que era necessário para encontrá-la; (3) O descritor HOG da região não possuía semelhanças suficientes com as amostras utilizadas no treinamento. No entanto, o maior problema desse método foi o tempo elevado necessário para realizar a procura, como exemplificado na Tabela 14, inviabilizando o uso desse método.

Tabela 14 – Comparação dos resultados obtidos nos 3 métodos.

Método	Vértebras Encontradas			Falsos Positivos			Falsos Negativos			Tempo de procura (minutos)			Redução de tempo do Método 2 para o 3
	1	2	3	1	2	3	1	2	3	1	2	3	
Imagem 1	5	8	8	1	0	0	3	0	0	14,068	326,311	8,074	97,52 %
Imagem 2	5	7	7	1	0	0	2	0	0	10,087	317,902	8,118	97,44 %
Imagem 3	1	6	7	0	0	0	6	1	0	11,481	361,691	11,071	96,94 %
Imagem 4	3	3	3	1	0	0	0	0	0	1,486	115,131	3,297	97,14 %

O Método 3 ao ser aplicado nas imagens de teste permitiu encontrar 100% das vértebras desejadas e manteve notas altas para as regiões detectadas. A nova estratégia de refinamento adotada permitiu reduzir em aproximadamente 97% do tempo de procura em relação ao Método 2, como é mostrado na última coluna da Tabela 14. O fator predominante para a redução do tempo é a ordem de variação nos parâmetros, que conduz a obtenção mais rápida de uma maior nota. Com a variação por primeiro da posição do *topLeft* seguido da variação da inclinação da janela de detecção em conjunto com um ajuste fino na posição do *topLeft*, obtém-se uma nota melhor reduzindo o número de chamadas do classificador SVM, conforme indicado nas Tabelas 11 e 13. Por outro lado, é importante destacar que o principal fator de custo de processamento do classificador SVM é a interpolação bilinear utilizada na rotação e redimensionamento da região a ser classificada.

## 5 Conclusões

Esta pesquisa teve como objetivo elaborar métodos de identificação e classificação de vértebras (cervicais, torácicas e lombares) em imagens médicas. Foi utilizado o algoritmo descritor de característica HOG juntamente com o classificador SVM. A sua implementação foi uma versão modificada da disponibilizada em McCormick (2013), com o objetivo de treinar o classificador para o reconhecimento de vértebras. Conforme mostram os resultados obtidos, as adaptações no algoritmo permitiram detectar vértebras com o classificador.

Foram realizados os treinamentos do classificador SVM para as 4 proporções (6:6, 6:7, 6:8 e 6:9) da janela de detecção, foram utilizadas 140 amostras, sendo 70 imagens de vértebras e 70 de não vértebras. A seleção das amostras para o treinamento foi realizada manualmente. Em seguida essas amostras de cada proporção foram submetidas aos seus respectivos treinamentos durando 1,74 minutos. Como pôde-se analisar nos resultados, esse número de amostras foi suficiente para detectar as vértebras. Porém, alguns falsos positivos foram encontrados no Método 1, indicando que o número de amostras negativas (não vértebras) deveriam ser aumentadas.

Para a avaliação do sistema de reconhecimento de vértebras, foram utilizadas imagens da região lombar da coluna vertebral, que não haviam sido utilizadas no treinamento. Os testes de reconhecimento das vértebras utilizaram as mesmas dimensões da janela de detecção do treinamento. Os resultados obtidos mostram que o classificador SVM realizou corretamente a detecção das vértebras das imagens de teste.

Foram implementados três métodos diferentes para percorrer as imagens em busca de vértebras. O Método 1 proposto inicialmente mostrou diversas deficiências, chegando a encontrar apenas 1 vértebra entre as 7 mostradas em uma imagem de teste. A falha neste método é devido a procura da janela de detecção ser realizada sem alterar a sua inclinação, detectando com isso apenas vértebras que estavam pouco inclinadas na imagem.

Conforme mostram os resultados do Método 2, a elaboração de uma estratégia que limita a área de procura em uma região logo abaixo (ou acima) da vértebra anteriormente encontrada e que permite alterar também o ângulo de inclinação da janela de detecção, melhorou em muito a detecção das vértebras, sendo encontradas cerca de 95% das vértebras presentes nas imagens testes. No entanto, o fato de ser necessário variar tanto a posição horizontal, a vertical, a inclinação, a escala e a proporção da janela de detecção, aumentou muito a complexidade computacional da busca, a qual foi mensurada através do tempo necessário para realizar a procura por toda a imagem. Portanto, ao utilizar a implementação desse método interpretado em Octave, foi necessário até 6 horas de processamento para a detecção das vértebras.



No Método 3 foi implementada uma mudança na ordem da variação dos parâmetros da busca do Método 2, bem como foi permitida uma maior precisão da posição horizontal e vertical da janela de detecção. Foi possível detectar 100% das vértebras nas imagens testadas, e obteve-se uma redução no tempo de procura de aproximadamente 97% em relação ao Método 2. Essa redução foi consequência direta da redução do número de chamadas do classificador SVM e da função de interpolação bilinear.

Apesar de ainda resultar em um tempo significativo na ordem de alguns minutos, o resultado obtido com o Método 3 atende ao objetivo principal deste trabalho, que era a detecção automática das vértebras presentes em uma imagem médica. Possíveis melhorias neste tempo são a sua implementação em linguagem de programação compilada, o uso do Matlab Compiler <sup>1</sup> que pode reduzir esse tempo de execução. Outra possibilidade é realizar o processo de interpolação bilinear através de uma função implementada em *hardware* enquanto que os demais processos poderiam ser realizados em *software*.

Durante os 3 métodos de procura, regiões foram consideradas vértebras se suas notas obtidas do classificador SVM fossem superiores a 0,4. Esse valor foi escolhido empiricamente, pois durante os testes iniciais a maioria das regiões que eram vértebras possuíam valores superiores a 0,4. Nos Métodos 2 e 3, além desse limite inicial de 0,4, também foi estabelecido que após o refinamento dos parâmetros só seriam classificadas como vértebras regiões com notas superiores a 0,5. Este limite foi adotado com o intuito de ter uma certeza maior que a região era uma vértebra.

Os julgamentos de falsos positivos e falsos negativos foram realizados manualmente, baseados na visualização das regiões detectadas ou não nas imagens médicas.

## 5.1 Trabalhos futuros

Como sugestão de trabalhos de continuidade dessa pesquisa, pode-se indicar algumas das deficiências encontradas e também algumas melhorias que poderiam ser realizadas:

1. Para reduzir o número de falsos positivos poderia-se ampliar o número de amostras de regiões que não são vértebras no treinamento, bem como utilizar regiões que resultaram em falsos positivos para serem adicionadas aos treinamentos futuros do sistema, isto poderia melhorar o desempenho neste quesito;
2. Para reduzir o número de falsos negativos sugere-se: i) permitir valores de ângulos de inclinação maiores que 12°, bem como utilizar passos menores que 3°; ii) permitir uma variação maior que 8 *pixels* tanto no deslocamento na direção horizontal como vertical da janela de detecção; iii) Incluir na fase do treinamento amostras de imagens

<sup>1</sup> [https://www.mathworks.com/content/dam/mathworks/tag-team/Objects/p/77493\\_Spr96Cleve.pdf](https://www.mathworks.com/content/dam/mathworks/tag-team/Objects/p/77493_Spr96Cleve.pdf)

que representam diferentes ângulos de inclinação e tipos de vértebras, principalmente incluindo cervicais, torácicas e lombares;

3. Para melhorar o processo de detecção também seria necessário incluir na fase de treinamento amostras de imagens DICOM de diferentes faixas etárias, dos gêneros masculino e feminino <sup>2</sup>;
4. Para permitir a designação das vértebras, poderia-se realizar o treinamento classificando inicialmente também vértebras de acordo com sua posição na coluna vertebral, utilizando posteriormente a posição relativa entre elas após a detecção para designá-las na imagem;
5. Em virtude dos métodos propostos dependerem de ter pelo menos uma vértebra com ângulo de inclinação pequeno, o sistema pode não detectar vértebras caso a imagem seja adquirida com o paciente posicionado de forma errada, ou com forte deformação na coluna vertebral. Uma possível solução para esta situação seria realizar uma estimativa inicial do eixo da coluna vertebral, para rotacionar a imagem antes de iniciar o processo;
6. Para reduzir o tempo de detecção das vértebras em uma imagem, poderiam-se utilizar técnicas heurísticas, como gradiente descendente, para acelerar a variação dos parâmetros visando atingir a nota máxima no classificador SVM. Outra abordagem poderia ser a utilização de linguagem de programação compilada, bem como implementar em *hardware* as funções com maior custo de processamento, principalmente a interpolação bilinear;
7. Testar os vários tipos de função Kernel, para verificar se a SVM aumenta sua generalização e conseqüentemente o número de falsos positivos seja reduzido;
8. Utilizar o *Gradient Vector Flow* (GVF) (SA et al., 2016) no lugar do retângulo colorido para destacar as vértebras encontradas, obtendo uma melhor segmentação e destaque dos contornos das vértebras detectadas.

---

<sup>2</sup> <http://www.afh.bio.br/sustenta/sustenta1.asp>  
<http://download.upf.br/editora/revistas/rfo/12-01/8.pdf>  
<http://www.drpaulosilveira.med.br/visualizar.php?id=1625501>

## Referências

- ADOBE. *O que é PDF?* 2017. Disponível em: <<https://acrobat.adobe.com/br/pt/why-adobe/about-adobe-pdf.html>>. Acesso em: 27 de julho de 2017. Citado na página 16.
- ANATOMIA, A. de. *COLUNA VERTEBRAL*. 2001. Disponível em: <<http://www.auladeanatomia.com/novosite/sistemas/sistema-esqueletico/coluna-vertebral/>>. Acesso em: 08 de dezembro de 2016. Citado na página 17.
- AZEVEDO-MARQUES, P. M. de; SALOMÃO, S. C. Pacs: Sistemas de arquivamento e distribuição de imagens. *Revista Brasileira de Física Médica*, 2009. Citado na página 23.
- BAILEY, R. *Anatomical Directional Terms and Body Planes*. 2017. Disponível em: <<https://www.thoughtco.com/anatomical-directional-terms-and-body-planes-373204>>. Acesso em: 01 de junho de 2017. Citado na página 19.
- BOAVENTURA, C. S. et al. Avaliação das indicações de ressonância magnética da pelve feminina em um centro de referência oncológico, segundo os critérios do colégio americano de radiologia. *SciELO Analytics*, 2017. Citado na página 23.
- CERNA, L. R. *Fusão de descritores de histogramas de gradientes para a detecção de faces baseado em uma cascata de classificadores*. Dissertação (Mestrado) — Universidade Federal de Ouro Preto, nov 2014. Citado 3 vezes nas páginas 28, 32 e 33.
- CHENG, H. et al. Segmentation of pedestrians with confidence level computation. *Signal Processing Systems*, v. 72, n. 2, p. 87–97, 2013. Disponível em: <<https://doi.org/10.1007/s11265-012-0708-0>>. Acesso em: 18 de junho de 2017. Citado na página 28.
- COMMONS, W. *Interpolação bilinear*. 2004. Disponível em: <[https://commons.wikimedia.org/wiki/File:Bilinear\\_interpolation.png](https://commons.wikimedia.org/wiki/File:Bilinear_interpolation.png)>. Acesso em: 01 de junho de 2017. Citado na página 30.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine Learning*, v. 20, n. 3, p. 273–297, 1995. Citado na página 31.
- COSMO, D. L. *Detecção de Pedestres Utilizando Descritores de Orientação do Gradiente e Auto Similaridade de Cor*. Dissertação (Mestrado) — Universidade Federal do Espírito Santo, nov 2014. Citado 4 vezes nas páginas 14, 26, 28 e 32.
- COSTA, E. L. D. M. et al. *UM ESTUDO DA COLUNA VERTEBRAL: POSICIONAMENTO E ANATOMIA*. 2013. Disponível em: <<http://aems.edu.br/iniciacao-cientifica/download/4c261f207f.pdf>>. Acesso em: 11 de dezembro de 2016. Citado 2 vezes nas páginas 17 e 18.
- DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. [S.l.: s.n.], 2005. v. 1, p. 886–893 vol. 1. ISSN 1063-6919. Citado 3 vezes nas páginas 26, 27 e 28.

- DETROZ, J. P. *Aplicação de Histograma de Gradientes Orientados para detecção de hidrômetros em imagens de fundo complexo*. 2014. Disponível em: <[http://www.joinville.udesc.br/portal/professores/andretavares/materiais/Apresentacao\\_Juliana.pdf](http://www.joinville.udesc.br/portal/professores/andretavares/materiais/Apresentacao_Juliana.pdf)>. Acesso em: 20 de junho de 2017. Citado na página 32.
- DICOM, B. *Armazenamento espacial*. 2017. Disponível em: <<http://www.dicomlibrary.com/dicom/study-structure/>>. Acesso em: 01 de junho de 2017. Citado na página 24.
- DISCO, H. de. *ANATOMIA DA COLUNA VERTEBRAL*. 2015. Disponível em: <<http://www.herniadedisco.com.br/conheca-sua-coluna/anatomia-da-coluna/>>. Acesso em: 14 de dezembro de 2016. Citado na página 18.
- DREAMSTIME. *T3 torácico das vértebras*. 2017. Disponível em: <<https://pt.dreamstime.com/ilustra%C3%A7%C3%A3o-stock-t-tor%C3%A1cico-das-v%C3%A9rtebras-image78412596>>. Acesso em: 08 de junho de 2017. Citado na página 19.
- EATON, J. W. *GNU Octave*. 2017. Disponível em: <<https://www.gnu.org/software/octave/download.html>>. Acesso em: 04 de julho de 2017. Citado na página 34.
- FALCAO, A. X. *Análise de Imagens - Aula 6: Características de Imagem*. 2008. Disponível em: <<http://www.ic.unicamp.br/~afalcao/mo445/aula6-old.pdf>>. Acesso em: 08 de junho de 2017. Citado na página 24.
- FICEL, M. O. *SAIBA O QUE É PACS E DICOM*. 2006. Disponível em: <[http://www.tecnologiaradiologica.com/materia\\_pacs\\_dicom.htm](http://www.tecnologiaradiologica.com/materia_pacs_dicom.htm)>. Acesso em: 17 de dezembro de 2016. Citado na página 15.
- FICEL, M. O. *SAIBA O QUE É PACS E DICOM*. 2006. Disponível em: <[http://www.tecnologiaradiologica.com/materia\\_pacs\\_dicom.htm](http://www.tecnologiaradiologica.com/materia_pacs_dicom.htm)>. Acesso em: 01 de junho de 2017. Citado 2 vezes nas páginas 23 e 24.
- GHELLERE, J. S. *DETECÇÃO DE OBJETOS EM IMAGENS POR MEIO DA COMBINAÇÃO DE DESCRITORES LOCAIS E CLASSIFICADORES*. 2015. Disponível em: <[http://repositorio.roca.utfpr.edu.br/jspui/bitstream/1/5454/1/MD\\_COCIC\\_2015\\_1\\_02.pdf](http://repositorio.roca.utfpr.edu.br/jspui/bitstream/1/5454/1/MD_COCIC_2015_1_02.pdf)>. Acesso em: 11 de junho de 2017. Citado na página 26.
- GONZALEZ, R. C. *Processamento Digital de Imagens*. third. [S.l.]: Pearson Prentice Hall, 2010. Citado 6 vezes nas páginas 15, 20, 21, 22, 29 e 30.
- HAGE, M. C. F. N. S.; IWASAKI, M. Imagem por ressonância magnética: princípios básicos. *SciELO Analytics*, v. 39, n. 4, 2009. Citado na página 23.
- HERBRICH, R. *Learning Kernel Classifiers: Theory and Algorithms*. [S.l.]: MIT Press, 2001. Citado na página 31.
- INTRINSICAL. *101 Artificial Intelligence and Machine Learning*. 2014. Disponível em: <<https://www.trekbbs.com/threads/101-artificial-intelligence-and-machine-learning.259000/page-3>>. Acesso em: 11 de junho de 2017. Citado na página 26.
- LEON, L. M. C. *Detecção de objetos em vídeos usando misturas de modelos baseados em partes deformáveis obtidas de um conjunto de imagem*. Dissertação (Mestrado) — Instituto de Matemática e Estatística da Universidade de São Paulo, oct 2012. Citado 2 vezes nas páginas 25 e 26.

LOOTUS, M.; KADIR, T.; ZISSERMAN, A. Vertebrae detection and labelling in lumbar mr images. In: *MICCAI Workshop: Computational Methods and Clinical Applications for Spine Imaging*. [S.l.: s.n.], 2013. Citado 2 vezes nas páginas 14 e 34.

LOOTUS, M.; KADIR, T.; ZISSERMAN, A. *Vertebrae Detection and Labelling in Lumbar MR Images*. 2013. Disponível em: <<https://www.robots.ox.ac.uk/~vgg/publications/2013/Lootus13/lootus13.pdf>>. Acesso em: 12 de dezembro de 2016. Citado 2 vezes nas páginas 26 e 35.

MCCORMICK, C. *HOG Person Detector Tutorial*. 2013. Disponível em: <<http://mccormickml.com/2013/05/09/hog-person-detector-tutorial/>>. Acesso em: 12 de agosto de 2016. Citado 6 vezes nas páginas 15, 32, 34, 35, 37 e 55.

MEDICA, R. *Tomografia Computadorizada (TC)*. 2016. Disponível em: <<http://www.radiacao-medica.com.br/tipos-de-imagens-medicas/raios-x/tomografia-computadorizada-ct>>. Acesso em: 08 de agosto de 2016. Citado na página 21.

MÉDICA, R. ao. *Radiografia (Raios-X Simples)*. 2013. Disponível em: <<http://www.radiacao-medica.com.br/tipos-de-imagens-medicas/raios-x/radiografia-raios-x-simples/>>. Acesso em: 16 de dezembro de 2016. Citado na página 20.

MONJA, R. Q. *Sistema Ósseo*. 2013. Disponível em: <<http://es.slideshare.net/rosaangelica30/el-sistema-esqueltico-informacin-muy-importante>>. Acesso em: 14 de dezembro de 2016. Citado na página 19.

MOREIRA, J.; GERCINA, C. *Confirma as doenças que mais dão afastamento no INSS*. 2014. Disponível em: <<http://www1.folha.uol.com.br/mercado/2014/09/1520341-veja-as-doencas-que-mais-dao-afastamento-no-inss.shtml>>. Acesso em: 12 de dezembro de 2016. Citado na página 14.

NOBREGA, A. I. da. *Técnicas de Imagem Por Tomografia Computadorizada*. 2014. Disponível em: <[http://www.umadosedeinteligencia.files.wordpress.com/2014/09/tc\\_apostila\\_almir.pdf](http://www.umadosedeinteligencia.files.wordpress.com/2014/09/tc_apostila_almir.pdf)>. Acesso em: 20 de outubro de 2016. Citado na página 22.

NUNES, F. L. S. *Introdução ao Processamento de Imagens Médicas para Auxílio ao Diagnóstico – Uma Visão Prática*. 2006. Disponível em: <<http://www.lbd.dcc.ufmg.br/colecoes/jai/2006/003.pdf>>. Acesso em: 08 de dezembro de 2016. Citado na página 21.

OKTAY, A. B.; AKGUL, Y. S. Simultaneous localization of lumbar vertebrae and intervertebral discs with svm based mrf. *IEEE TMI*, 2013. Citado na página 14.

PIXEON. *O que é DICOM e quais são seus benefícios*. 2014. Disponível em: <<http://pixon.com.br/artigos/774/o-que-e-dicom-e-quais-sao-seus-beneficios/>>. Acesso em: 01 de junho de 2017. Citado na página 24.

PIXEON. *PACS e RIS*. 2015. Disponível em: <<http://pixon.com.br/artigos/3009/a-importancia-do-beneficio-da-integracao-pacs-e-ris/>>. Acesso em: 01 de junho de 2017. Citado na página 34.

- SA, R. et al. Fast scale-invariant lateral lumbar vertebrae detection and segmentation in x-ray images. In: *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [s.n.], 2016. p. 1054–1057. ISSN 1557-170X. Disponível em: <<https://www.ncbi.nlm.nih.gov/labs/articles/28268506/>>. Acesso em: 2 de agosto de 2017. Citado 3 vezes nas páginas 14, 34 e 57.
- SANTOS, S. G. de O. *Detecção de Pedestres com Oclusão*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, aug 2013. Acesso em: 17 de junho de 2017. Citado na página 26.
- SCOPPETTA, C. *Ressonância magnética*. 2016. Disponível em: <<http://www.clinicascoppetta.com.br/exames/ressonancia-magnetica/>>. Acesso em: 08 de dezembro de 2016. Citado na página 23.
- SEERAM, E. *Computed Tomography: Physical Principles, Clinical Applications and Quality Control*. third. [S.l.]: Saunders Elsevier, 2009. Citado na página 22.
- SILVA, A. T. da. *Descritores de Imagem*. Tese (Doutorado) — UDESC, <http://www.joinville.udesc.br/portal/professores/andretavares/materiais/descritores2.pdf>, mar 2014. Acesso em: 08 de junho de 2017. Citado 3 vezes nas páginas 14, 25 e 26.
- SOCIAL, P. *Tabelas – CID-10*. 2016. Disponível em: <<http://www.previdencia.gov.br/dados-abertos/estatsticas/tabelas-cid-10/>>. Acesso em: 12 de dezembro de 2016. Citado na página 14.
- SPERANDIO, M. C.; SANTOS, P. E. *INTERPRETAÇÃO DE IMAGENS DE UM ROBÔ MÓVEL USANDO LÓGICA PROBABILÍSTICA*. 2011. Disponível em: <<http://fei.edu.br/70anos/simposio/trabalhos/EI%C3%A9trica/Interpreta%C3%A7%C3%A3o%20Volum%C3%A9tricas,%20Viscosim%C3%A9tricas%20e%20Ac%C3%Basticas%20de%20S.pdf>>. Acesso em: 11 de junho de 2017. Citado na página 25.
- TANG, Y. *Deep Learning using Linear Support Vector Machines*. 2013. Disponível em: <<http://deeplearning.net/wp-content/uploads/2013/03/dlsvm.pdf>>. Acesso em: 29 de junho de 2017. Citado na página 32.
- VAPNIK, V. N. *The nature of statistical learning theory*. [S.l.]: Springer-Verlag, 1995. Citado na página 31.
- VIEIRAI, S. L.; OLIVEIRA, L. N. de; CARNEIRO, A. A. O. Princípios físicos da elastografia por ressonância magnética. *SciELO Analytics*, v. 36, n. 2, 2014. Citado na página 22.
- WEBER, E. C.; VILENSKY, J. A.; CARMICHAEL, S. W. *Netter Anatomia em Imagens Essencial*. first. [S.l.]: Elsevier, 2009. Citado 3 vezes nas páginas 20, 21 e 22.

## Apêndices

# APÊNDICE A –

## Informação das *tags* DICOM

1	#	Dicom-File-Format		
2				
3				
4	#	Dicom-Data-Set		
5	#	Used TransferSyntax: Little Endian Explicit		
6	(0008,0008)	CS []	#	28, 5
		ImageType		
7	(0008,0013)	TM [085024.328000]	#	14, 1
		InstanceCreationTime		
8	(0008,0016)	UI =MRImageStorage	#	26, 1
		SOPClassUID		
9	(0008,0050)	SH [68883]	#	6, 1
		AccessionNumber		
10	(0008,0060)	CS [MR]	#	2, 1
		Modality		
11	(0008,1010)	SH [MRC29053]	#	8, 1
		StationName		
12	(0008,1030)	LO [COLUNAS^COLUNA LOMBAR]	#	22, 1
		StudyDescription		
13	(0008,103e)	LO [t1_tse_sag_FIL_1]	#	16, 1
		SeriesDescription		
14	(0010,0010)	PN []	#	32, 1
		PatientName		
15	(0010,0020)	LO [143064]	#	6, 1
		PatientID		
16	(0010,0030)	DA [19460825]	#	8, 1
		PatientBirthDate		
17	(0010,0040)	CS [F]	#	2, 1
		PatientSex		
18	(0018,0020)	CS [SE]	#	2, 1
		ScanningSequence		
19	(0018,0080)	DS [495]	#	4, 1
		RepetitionTime		
20	(0018,0081)	DS [16]	#	2, 1
		EchoTime		
21	(0018,0094)	DS [100]	#	4, 1
		PercentPhaseFieldOfView		
22	(0018,0095)	DS [115]	#	4, 1
		PixelBandwidth		
23	(0018,1000)	LO [29053]	#	6, 1




---

	DeviceSerialNumber			
24	(0018,1020) LO []	#	20, 1	
	SoftwareVersions			
25	(0018,1030) LO []	#	12, 1	
	ProtocolName			
26	(0018,1251) SH [TxCoil]	#	6, 1	
	TransmitCoilName			
27	(0018,1310) US 320\0\0\208	#	8, 4	
	AcquisitionMatrix			
28	(0018,1312) CS [COL]	#	4, 1	
	InPlanePhaseEncodingDirection			
29	(0018,5100) CS [HLS]	#	4, 1	
	PatientPosition			
30	(0028,0002) US 1	#	2, 1	
	SamplesPerPixel			
31	(0028,0004) CS [MONOCHROME2]	#	12, 1	
	PhotometricInterpretation			
32	(0028,0008) IS [1]	#	2, 1	
	NumberOfFrames			
33	(0028,0010) US 320	#	2, 1	Rows
34	(0028,0011) US 320	#	2, 1	
	Columns			
35	(0028,0030) DS [1.03125\1.03125]	#	16, 2	
	PixelSpacing			
36	(0028,0100) US 16	#	2, 1	
	BitsAllocated			
37	(0028,0101) US 12	#	2, 1	
	BitsStored			
38	(0028,0102) US 11	#	2, 1	
	HighBit			
39	(0028,0103) US 0	#	2, 1	
	PixelRepresentation			
40	(0028,1050) DS [1012]	#	4, 1	
	WindowCenter			
41	(0028,1051) DS [2119]	#	4, 1	
	WindowWidth			
42	(0028,1055) LO [WINDOW1]	#	8, 1	
	WindowCenterWidthExplanation			
43	(0032,1033) LO [RESSONANCIA]	#	12, 1	
	RequestingService			
44	(0032,1060) LO [RM COLUNA LOMBAR]	#	16, 1	
	RequestedProcedureDescription			

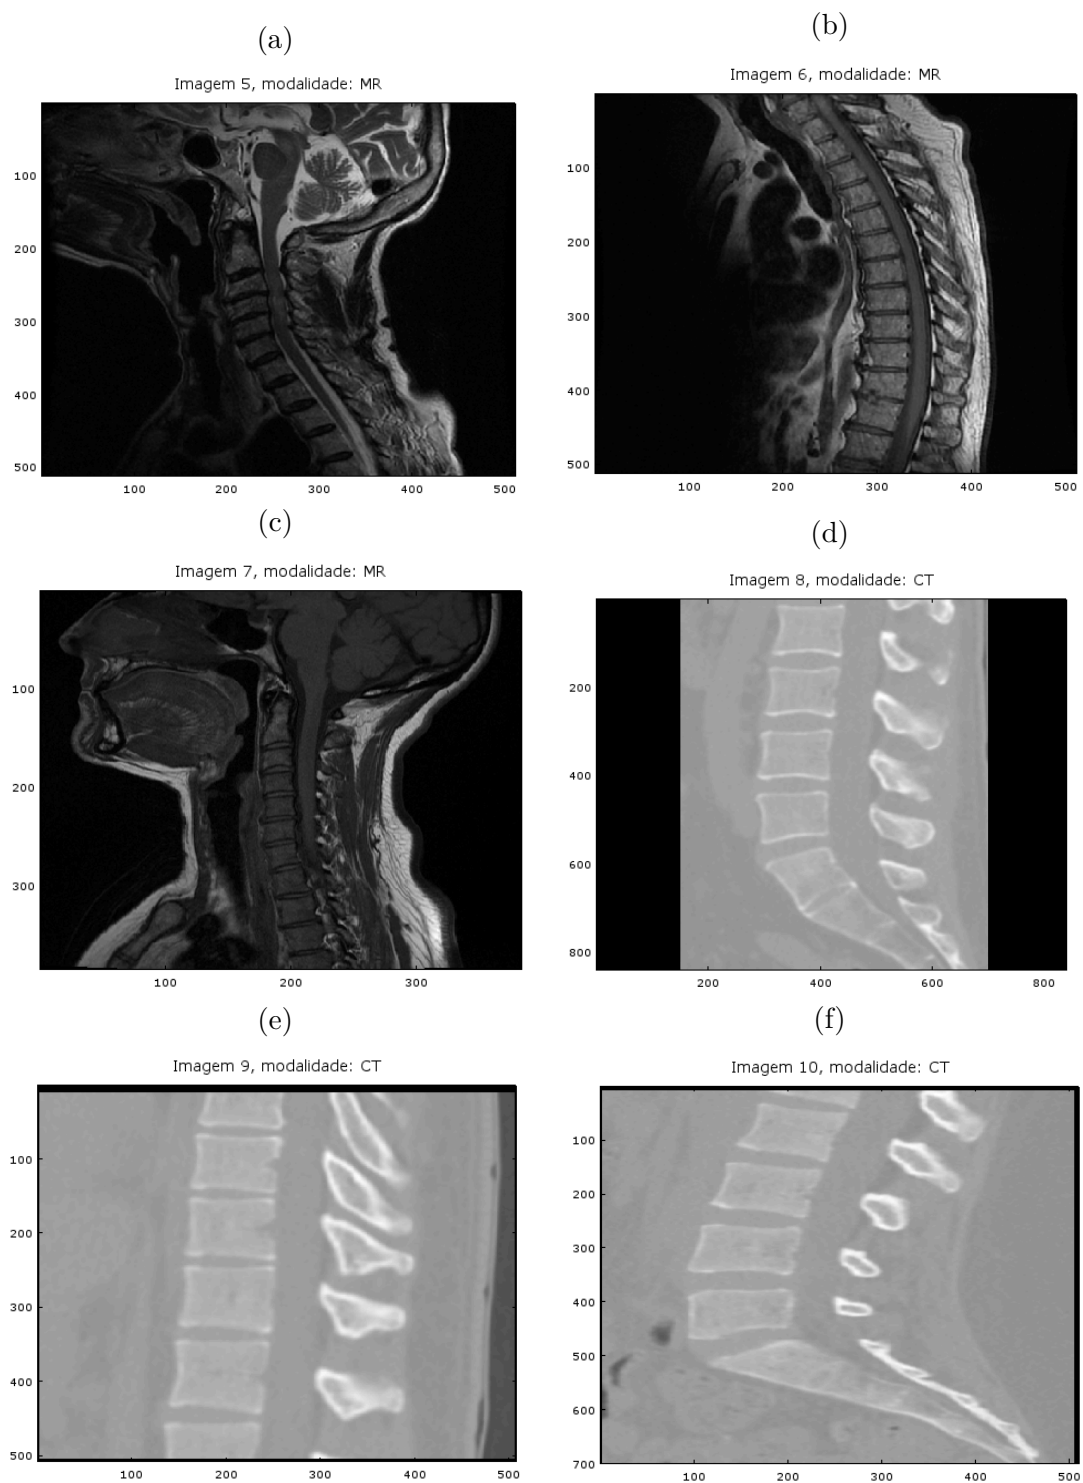
## APÊNDICE B –

Figura 32 – Imagens no formato DICOM utilizadas no treinamento do classificador SVM.



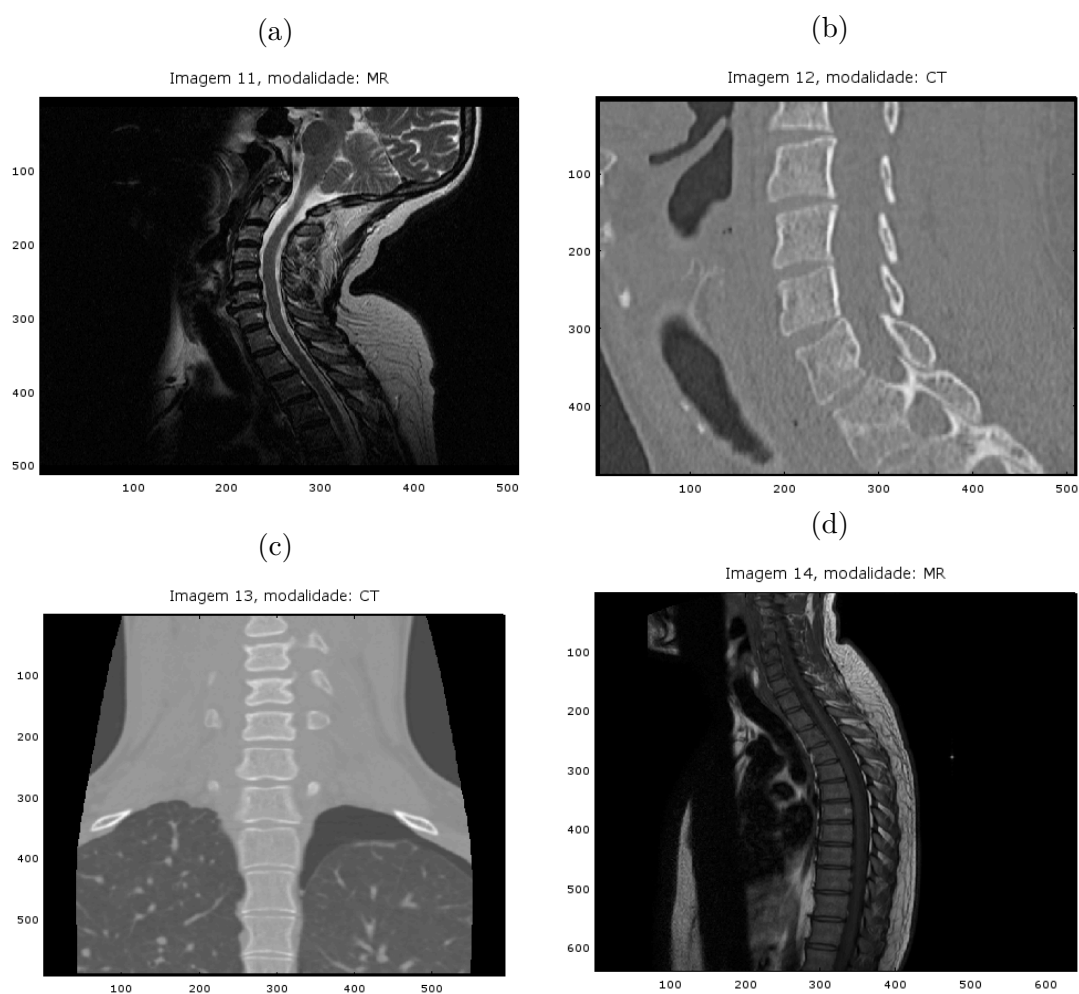
<sup>1</sup>CT - Tomografia Computadorizada. <sup>2</sup>MR - Ressonância Magnética.

Figura 33 – Imagens no formato DICOM utilizadas no treinamento do classificador SVM (cont.)



<sup>3</sup>CT - Tomografia Computadorizada. <sup>4</sup>MR - Ressonância Magnética.

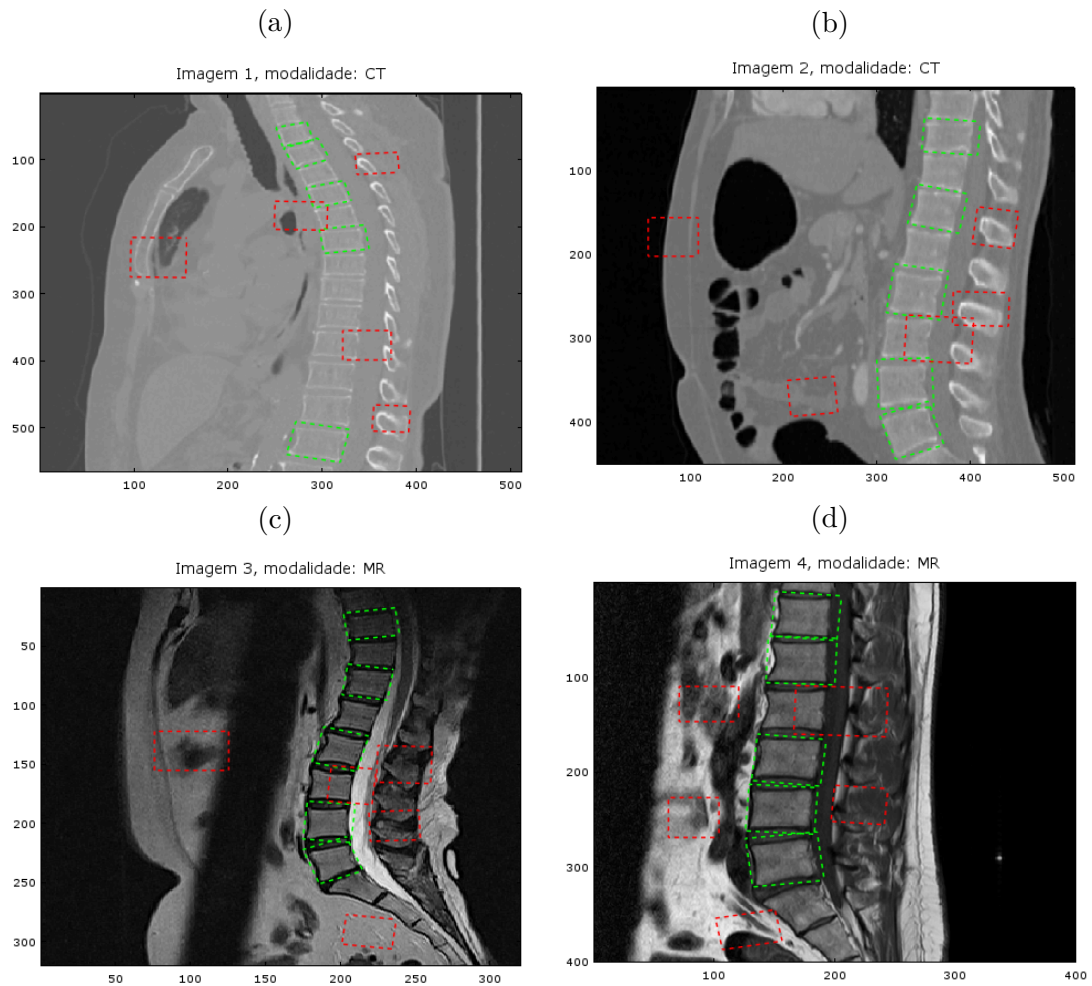
Figura 34 – Imagens no formato DICOM utilizadas no treinamento do classificador SVM (cont.)



<sup>5</sup>CT - Tomografia Computadorizada. <sup>6</sup>MR - Ressonância Magnética.

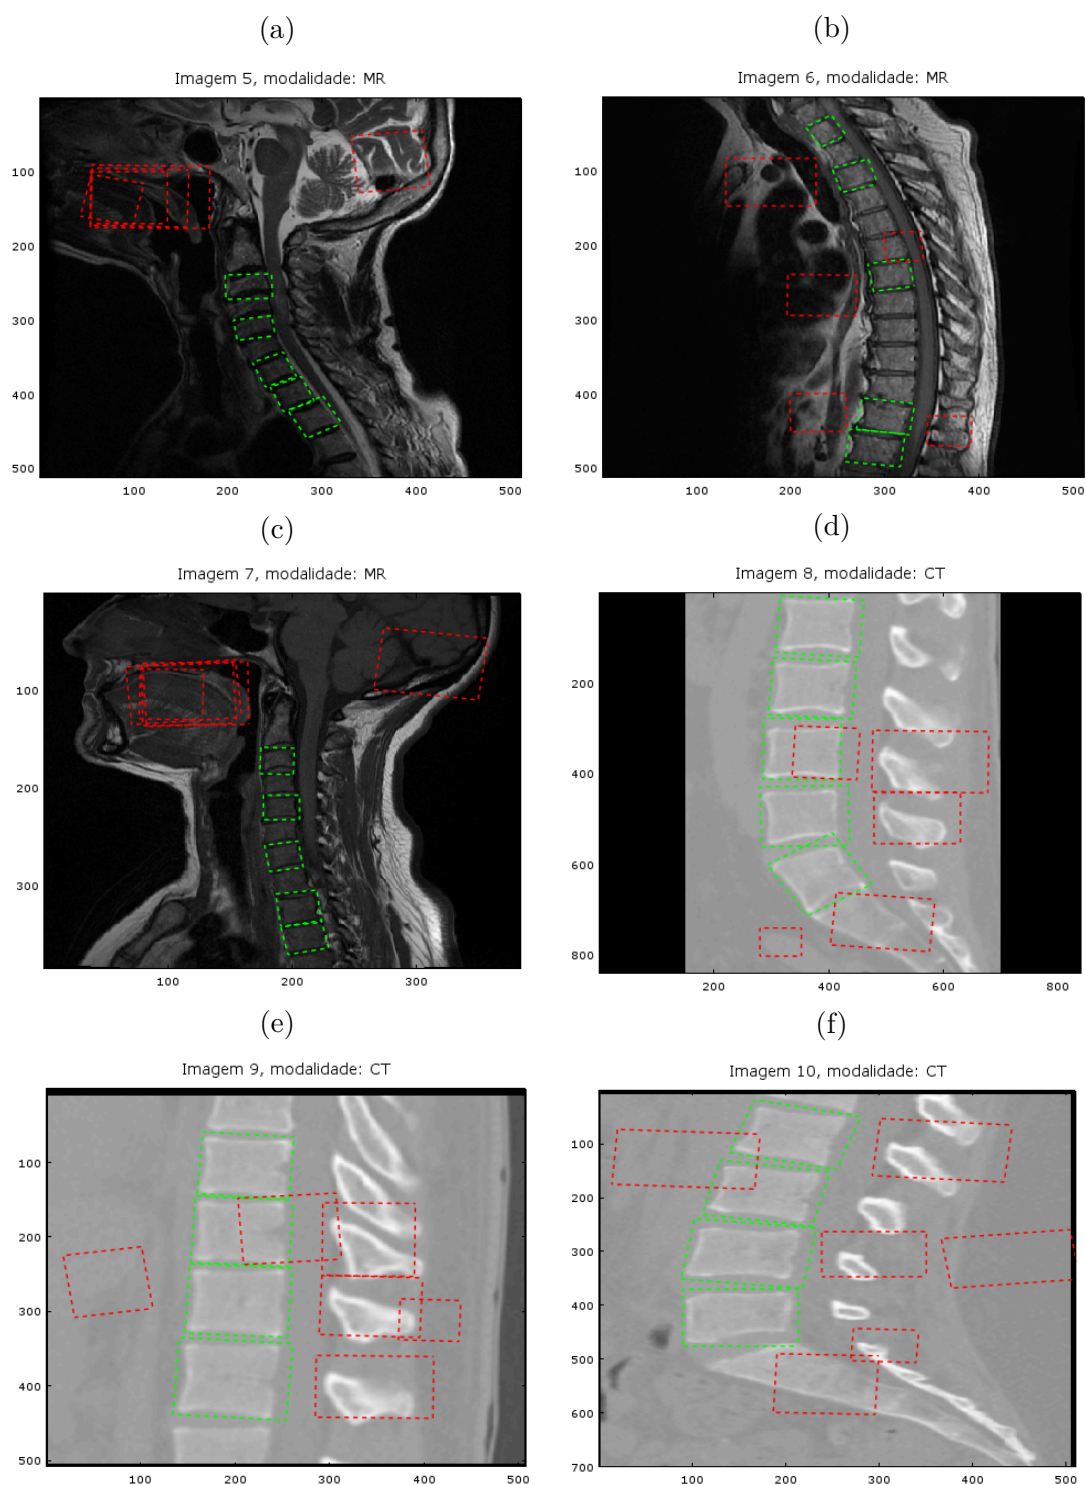
# APÊNDICE C –

Figura 35 – Amostras das imagens utilizadas no treinamento do classificador SVM.



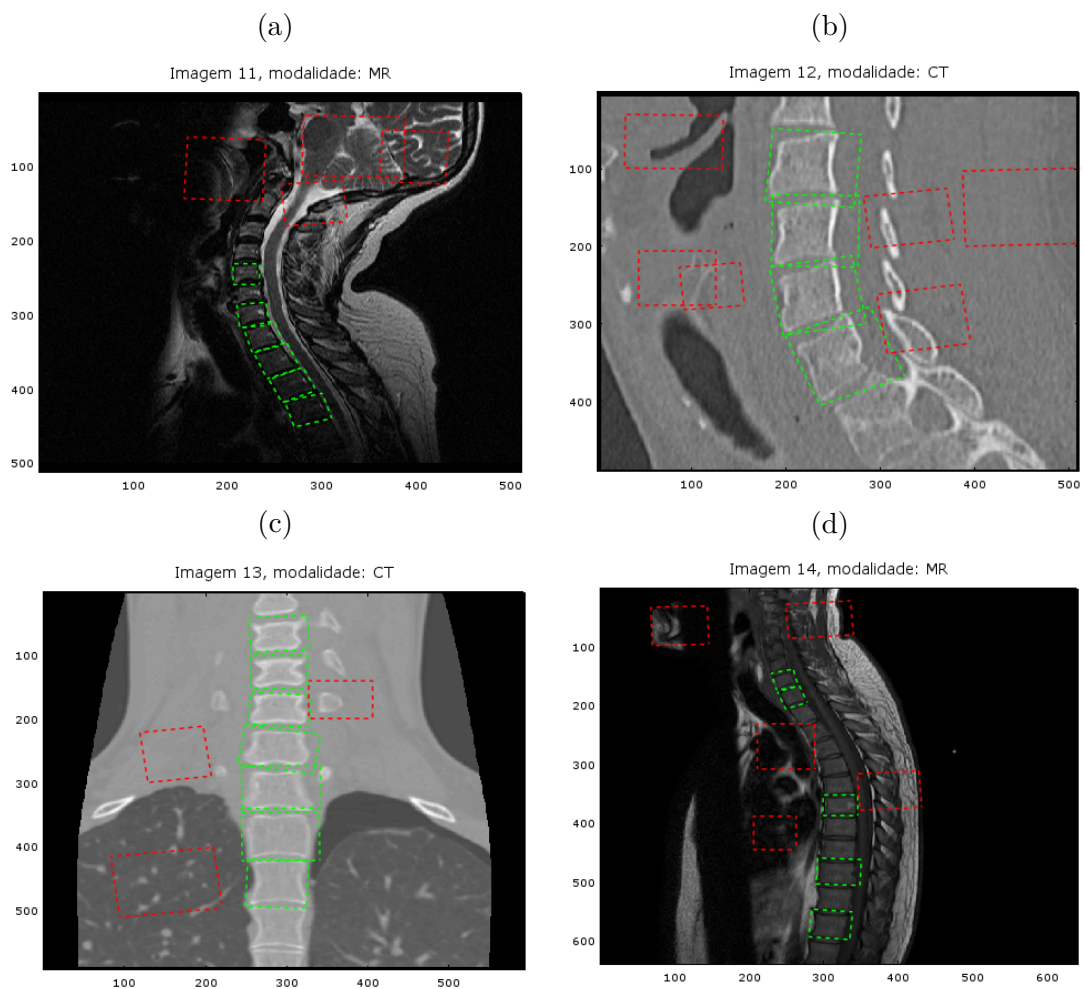
<sup>1</sup>Borda verde tracejada são as vértebras. <sup>2</sup>Borda vermelha tracejada são as não vértebras.

Figura 36 – Amostras das imagens utilizadas no treinamento do classificador SVM (cont.)



<sup>3</sup>Borda verde tracejada são as vértebras. <sup>4</sup>Borda vermelha tracejada são as não vértebras.

Figura 37 – Amostras das imagens utilizadas no treinamento do classificador SVM (cont.)




<sup>5</sup>Borda verde tracejada são as vértebras. <sup>6</sup>Borda vermelha tracejada são as não vértebras.

## APÊNDICE D –

Figura 38 – Imagens médicas utilizadas nos testes de detecção de vértebras.


(a) Imagem de teste 1

Imagem 1, região: Lombar, modalidade: MR



(b) Imagem de teste 2

Imagem 2, região: Lombar, modalidade: MR




(c) Imagem de teste 3

Imagem 3, região: Lombar, modalidade: MR



(d) Imagem de teste 4

Imagem 4, região: Lombar, modalidade: CT





# APÊNDICE E – Pseudocódigo dos 3 métodos

```

1  CONDICÕES DE ENTRADA
2
3  valores iniciais das dimensões das regiões de busca
4  prop_h : número de células horizontais
5  prop_v : número de células verticais (CONSTANTE = 6)
6  n_col  : número de células na direção horizontal da matriz_hist_norm
7          (CONSTANTE = (n_pixel_hor / 8) - 1)
8  n_lin  : número de células na direção vertical da matriz_hist_norm
9          (CONSTANTE = (n_pixel_vert / 8) - 1)
10
11 ALGORITMO METODO1 – Procura
12   VAR      matriz_hist_norm
13   CONDICÕES DE ENTRADA {col <= 1, lin <= 1, prop_h <= 6}
14   DEFINE desvios de procura {d_col, d_lin, d_propH}
15   DEFINE prop_v <= 6;
16
17   PARA d_propH EM {6 7 8 9} FAÇA
18     PARA d_col EM {1 .. n_col - d_propH} FAÇA
19       PARA d_lin EM {1 .. n_lin - prop_v} FAÇA
20
21         DEFINE regio_a_analisar <= seleciona_Hist_regiao(matriz_hist_norm,
22           d_lin:d_lin+prop_v, d_col:d_col+d_propH)
23         DEFINE nota_p <= classificador_SVM(regiao_a_analisar, d_propH)
24
25         SE (nota_p > 0.4) ENTAO
26           DEFINE dim_vertebra <= (d_lin, d_lin+prop_v, d_col, d_col+d_propH,
27             d_propH)
28           ESCREVA (Uma vertebra foi identificada)
29         FIM-SE
30
31       FIM-PARA
32     FIM-PARA
33   FIM-PARA
34 FIM-ALGORITMO

```

Listagem E.1 – Pseudocódigo da estratégia de procura do Método 1.

```

1  CONDICÕES DE ENTRADA
2
3  valores iniciais das dimensões de procura sem refinamento da região identificada
   como vertebra
4  img: Imagem da coluna vertebral que está sendo analisada
5  x:    posição horizontal em pixels do canto superior esquerdo da região a ser
       refinada
6  y:    posição vertical em pixels do canto superior esquerdo da região a ser refinada
7  a:    inclinação em graus
8  e:    fator da escala
9  prop_h: número de células horizontais da região de busca
10 prop_v: número de células verticais da região de busca (CONSTANTE = 6)
11
12
13 ALGORITMO MÉTODO 2- Procura
14   VARz
15   CONDICÕES DE ENTRADA {img, x, y, a, e, prop_h}
16   DEFINE notaMaxP <= 0;
17
18   LACO1: PARA d_x EM {0 -4 4 -8 8} FAÇA
19       LACO2: PARA d_y EM {0 -4 4 -8 8} FAÇA
20           LACO3: PARA d_ph EM {6 7 8 9} FAÇA
21               LACO4: PARA d_e EM {100 95 105 90 110} FAÇA
22                   LACO5: PARA d_a EM {0 -3 3 -6 6 -9 9 -12 12} FAÇA
23
24                       DEFINE regioAnalizar <= selecionaRegiao_RotacionalImagem(img,
25                           x+d_x, y+d_y, a+d_a, e+d_e, d_ph)
26                       DEFINE notaP <= descritorHOG_classificadorSVM(regioAnalizar,
27                           d_ph)
28
29                       SE (notaP > notaMaxP) ENTAO
30                           DEFINE notaMaxP <= notaP
31                           DEFINE dimVertebra <= {x+d_x, y+d_y, a+d_a, e+d_e, d_ph}
32
33                       SE (notaMaxP > 0.9) ENTAO
34                           FIM TODOS LACOS
35                       FIM-SE
36                   FIM-SE
37               FIM DO LACO 5
38           FIM DO LACO 4
39       FIM DO LACO 3
40   FIM DO LACO 2
41   FIM DO LACO 1
42 FIM-ALGORITMO

```

Listagem E.2 – Pseudocódigo da estratégia de procura do Método 2.

```


1  CONDICÕES DE ENTRADA
2
3  valores iniciais das dimensões de procura sem refinamento da região identificada como
   vertebra
4  img: Imagem da coluna vErtebral que esta sendo analisada
5  x:   posicao horizontal em pixels do canto superior esquerdo da região que sera
       refinada
6  y:   posicao vertical em pixels do canto superior esquerdo da região que sera
       refinada
7  a:   inclinacao em graus
8  e:   fator da escala
9  prop_h: numero de celulas horizontais da região de busca
10 prop_v: numero de celulas verticais da região de busca (CONSTANTE = 6)
11
12
13 ALGORITMO METODO 3 – Procura
14  VAR
15  CONDICÕES DE ENTRADA {img, x, y, a, e, prop_h}
16  DEFINE notaMaxP <= 0;
17
18  LACO1: PARA d_x EM {0 -4 4 -8 8} FACA
19    LACO2: PARA d_y EM {0 -4 4 -8 8} FACA
20      DEFINE regioaoAnalisar <= selecionaRegiao_RotacionalImagem(img, x+d_x,
21        y+d_y, a, e, prop_h)
22      DEFINE notaP <= descritorHOG_classificadorSVM(regiaoAnalisar, prop_h)
23      SE (notaP > notaMaxP) ENTAO
24        DEFINE notaMaxP <= notaP;
25        DEFINE x2 <= x+d_x;
26        DEFINE y2 <= y+d_y;
27        DEFINE dimVertebra <= {x2, y2, a, e, prop_h}
28        SE (notaMaxP > 0.9)
29          FIM DA PROCURA
30      FIM DO LACO 2
31    FIM DO LACO 1
32
33  LACO3: PARA d_a EM {0 -3 3 -6 6 -9 9 -12 12} FACA
34    LACO4: PARA d_x EM {-2 0 2} FACA
35      LACO5: PARA d_y EM {-2 0 2} FACA
36        DEFINE regioaoAnalisar <= selecionaRegiao_RotacionalImagem(img, x2+d_x,
37          y2+d_y, a+d_a, e, prop_h)
38        DEFINE notaP <= descritorHOG_classificadorSVM(regiaoAnalisar, prop_h)
39        SE (notaP > notaMaxP) ENTAO
40          DEFINE notaMaxP <= notaP;
41          DEFINE x3 <= x2 + d_x;
42          DEFINE y3 <= y2 + d_y;
43          DEFINE a2 <= a+d_a;
44          DEFINE dimVertebra <= {x3, y3, a2, e, prop_h}
45          SE (notaMaxP > 0.9)
46            FIM DA PROCURA
47          FIM DO LACO 5
48        FIM DO LACO 4
49      FIM DO LACO 3
50
51  LACO6: PARA d_ph EM {6 7 8 9} FACA
52    LACO7: PARA d_e EM {100 95 105 90 110} FACA
53      DEFINE regioaoAnalisar <= selecionaRegiao_RotacionalImagem(img, x3,
54        y3, a2, e+d_e, d_ph)
55      DEFINE notaP <= descritorHOG_classificadorSVM(regiaoAnalisar, d_ph)
56      SE (notaP > notaMaxP) ENTAO
57        DEFINE notaMaxP <= notaP;
58        DEFINE dimVertebra <= {x3, y3, a2, e+d_e, d_ph}
59        SE (notaMaxP > 0.9)
60          FIM DA PROCURA
61      FIM DO LACO 7
62    FIM DO LACO 6

```

Listagem E.3 – Pseudocódigo da estratégia de procura do Método 3.

## APÊNDICE F – Método 1: Resultados

Figura 39 – Regiões detectadas como vértebras com o Método 1 para a imagem de teste 2.




<sup>1</sup>Os retângulos indicam as regiões detectadas. <sup>2</sup>As cores indicam as faixas de notas do classificador. <sup>3</sup>Os números indicam a ordem de procura. <sup>4</sup>A região 4 representa um falso positivo.

Tabela 15 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 1. Imagem de teste 2.

Região	Proporção Horizontal	TopLeft (y,x)	Nota classificador SVM (notaP)
1	7	(8, 200)	0,48672
2	7	(8, 208)	0,67657
3	7	( 8, 216)	0,52525
4	6	(8, 384)	0,53341
5	7	(16, 208)	0,43949
6	7	(112, 192)	0,51707
7	7	(160, 184)	0,49004
8	7	(168, 184)	0,43602
9	7	(216, 184)	0,51936
10	7	(224, 176)	0,67398
11	7	(224, 184)	0,52086
12	7	(280,184)	0,60472
<b>Média</b>			<b>0,4789</b>

Figura 40 – Regiões detectadas como vértebras com o Método 1 para a imagem de teste 3.

**Imagem analisada: img3, com a escala inicial: 100**




<sup>5</sup>Os retângulos indicam as regiões detectadas. <sup>6</sup>As cores indicam as faixas de notas do classificador. <sup>7</sup>Os números indicam a ordem de procura.

Tabela 16 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 1. Imagem de teste 3.

Região	Proporção Horizontal	TopLeft (y,x)	Nota classificador SVM (notaP)
1	7	(248, 224)	0,40991
2	7	(248, 332)	0,54017
Média			<b>0,4750</b>

Figura 41 – Regiões detectadas como vértebras com o Método 1 para a imagem de teste 4.




<sup>8</sup>Os retângulos indicam as regiões detectadas. <sup>9</sup>As cores indicam as faixas de notas do classificador. <sup>10</sup>Os números indicam a ordem de procura. <sup>11</sup>A região 5 representa um falso positivo.

Tabela 17 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 1. Imagem de teste 4.

Região	Proporção Horizontal	TopLeft (y,x)	Nota classificador SVM (notaP)
1	6	(32, 48)	0,44933
2	6	(88, 40)	0,83549
3	7	(88, 48)	0,58639
4	6	(96, 40)	0,44805
5	7	(104, 112)	0,40636
6	6	(144, 48)	0,51469
<b>Média</b>			<b>0,5400</b>

## APÊNDICE G – Método 2: Resultados

Figura 42 – Regiões detectadas como vértebras com o Método 2 para a imagem de teste 2.




<sup>1</sup>Os retângulos indicam as regiões detectadas. <sup>2</sup>As cores indicam as faixas de notas do classificador. <sup>3</sup>Os números indicam a ordem de procura.

Tabela 18 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 2. Imagem de teste 2.

Região	TopLeft (y,x)	Escala	Proporção Horizontal	Ângulo de inclinação	Nota obtida do Classificador (SVM)	Tempo de Procura (min)
1	(6,72 , 210,49)	90 %	7	9	0,90105	5,5354
2	(46,68 , 202,55)	110 %	7	3	0,86441	62,342
3	(96,98 , 184,52)	110 %	7	-3	0,83487	60,635
4	(150,16 , 180,09)	100 %	7	0	0,91162	5,4204
5	(210,48 , 169,68)	105 %	7	-9	0,87592	61,352
6	(273,46 , 171,58)	95 %	7	-9	0,85444	60,947
7	(333,43 , 181,44)	100 %	7	-9	0,77442	61,555
Média					0,8595	45,3981

Figura 43 – Regiões detectadas como vértebras com o Método 2 para a imagem de teste 3.




<sup>4</sup>Os retângulos indicam as regiões detectadas. <sup>5</sup>As cores indicam as faixas de notas do classificador. <sup>6</sup>Os números indicam a ordem de procura.

Tabela 19 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 2. Imagem de teste 3.

Região	TopLeft (y,x)	Escala	Proporção Horizontal	Ângulo de inclinação	Nota obtida do Classificador (SVM)	Tempo de Procura (min)
1	( 234,53 , 224,13)	110 %	7	6	0,69249	61,468
2	(177,69 , 233,05)	100 %	7	6	0,70231	60,057
3	(125,25 , 258,51)	90 %	7	6	0,77487	60,009
4	(74,23 , 270,99)	105 %	7	-3	0,72348	59,791
5	(33,40 , 278,58)	95 %	7	-6	0,64922	60,006
6	(297,71 , 217,15)	110 %	7	-12	0,70328	60,155
Média					<b>0,7076</b>	<b>60,2477</b>



Figura 44 – Regiões detectadas como vértebras com o Método 2 para a imagem de teste 4.




<sup>7</sup>Os retângulos indicam as regiões detectadas. <sup>8</sup>As cores indicam as faixas de notas do classificador. <sup>9</sup>Os números indicam a ordem de procura.

Tabela 20 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 2. Imagem de teste 4.

Região	TopLeft (y,x)	Escala	Proporção Horizontal	Ângulo de inclinação	Nota obtida do Classificador (SVM)	Tempo de Procura (min)
1	(20,36 , 52,37)	105 %	7	12	0,86773	60,766
2	(77,77 , 38,49)	100 %	7	-6	0,93499	24,469
3	(141,92 , 31,64)	100 %	7	-12	0,91360	29,896
Média					0,9054	48,667

## APÊNDICE H – Método 3: Resultados

Figura 45 – Regiões detectadas como vértebras com o Método 3 para a imagem de teste 2.




<sup>1</sup>Os retângulos indicam as regiões detectadas. <sup>2</sup>As cores indicam as faixas de notas do classificador. <sup>3</sup>Os números indicam a ordem de procura.

Tabela 21 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 3. Imagem de teste 2.

Região	TopLeft (y,x)	Escala	Proporção Horizontal	Ângulo de inclinação	Nota obtida do Classificador (SVM)	Tempo de Procura (min)
1	(2,56 , 207,29)	100 %	7	3	0,90055	0,4919
2	(46,07 , 203,01)	100 %	7	9	0,86488	1,4767
3	(98,97 , 185,61)	105 %	7	0	0,77946	1,2592
4	(153,02 , 181,24)	100 %	7	-3	0,90655	0,4727
5	(211,32 , 168,93)	105 %	7	-9	0,88981	1,4291
6	(272,29 , 171,12)	100 %	7	-9	0,86644	1,4389
7	( 334,46 , 183,03)	95 %	7	-9	0,78648	1,4178
<b>Média</b>					<b>0,8563</b>	<b>1,1409</b>

Figura 46 – Regiões detectadas como vértebras com o Método 3 para a imagem de teste 3.




<sup>4</sup>Os retângulos indicam as regiões detectadas. <sup>5</sup>As cores indicam as faixas de notas do classificador. <sup>6</sup>Os números indicam a ordem de procura e as regiões correspondentes na tabela abaixo.

Tabela 22 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 3. Imagem de teste 3.

Região	TopLeft (y,x)	Escala	Proporção Horizontal	Ângulo de inclinação	Nota obtida do Classificador (SVM)	Tempo de Procura (min)
1	(237,27 , 223,56)	105 %	7	3	0,69052	2,8524
2	(180,03 , 236,71)	100 %	7	9	0,70755	1,2273
3	(125,14 , 260,17)	95 %	7	6	0,75458	1,3792
4	(75,28 , 271,79)	100 %	7	-3	0,73108	1,3827
5	(33,98 , 279,50)	100 %	7	-6	0,63905	1,3842
6	(296,97 , 217,81)	110 %	7	-9	0,62351	1,2981
7	(355,58 , 227,51)	100 %	7	-12	0,50258	1,4269
Média					<b>0,66412</b>	<b>1,5644</b>

Figura 47 – Regiões detectadas como vértebras com o Método 3 para a imagem de teste 4.

**Imagem analisada: img4, com a escala inicial: 45**



<sup>7</sup>Os retângulos indicam as regiões detectadas. <sup>8</sup>As cores indicam as faixas de notas do classificador. <sup>9</sup>Os números indicam a ordem de procura.

Tabela 23 – Parâmetros obtidos para a detecção das regiões classificadas como vértebras pelo Método 3. Imagem de teste 4.

Região	TopLeft (y,x)	Escala	Proporção Horizontal	Ângulo de inclinação	Nota obtida do Classificador (SVM)	Tempo de Procura (min)
1	(21,53 , 47,51)	100 %	7	12	0,83230	1,2612
2	( 81,14 , 33,01)	100 %	6	-9	0,88375	1,2265
3	(143,31 , 34,54)	100 %	7	-9	0,94840	0,8086
Média					<b>0,8881</b>	<b>1,0987</b>